

Die Bedeutung des
»Index of Consumer Sentiment« (ICS)
für die Prognose
US-amerikanischer diskretionärer
Konsumausgaben

Dissertation

vorgelegt dem Fachbereich Rechts- und Wirtschaftswissenschaften
der Johannes Gutenberg-Universität in Mainz
zur Erlangung des Grades eines Doktors der Staatswissenschaften
(Dr. rer. pol.)

von

Jürgen Doeblin
Konstanz

1979



Digitized by the Internet Archive
in 2026

https://archive.org/details/IA41552618_0085

Die Bedeutung des
»Index of Consumer Sentiment« (ICS)
für die Prognose
US-amerikanischer diskretionärer
Konsumausgaben

Dissertation

vorgelegt dem Fachbereich Rechts- und Wirtschaftswissenschaften
der Johannes Gutenberg-Universität in Mainz
zur Erlangung des Grades eines Doktors der Staatswissenschaften
(Dr. rer. pol.)

von

Jürgen Doeblin
Konstanz
1979



Erstberichterstatter: Prof. Dr. Heinz Stöwe
Zweitberichterstatter: Prof. Dr. Peter Schulze
Tag der mündlichen Prüfung: 7. Februar 1979

Die Dissertation entstand zum größten Teil während eines Forschungsaufenthaltes in den Vereinigten Staaten von Amerika.

Prof. Granger, Economics Departement, University of California, San Diego, und Prof. Strümpel, Institute for Social Research, University of Michigan, Ann Arbor, förderten die Dissertation durch die großzügige Bereitstellung von Arbeitsmöglichkeiten. Prof. Stöwe und Prof. Schulze, beide Johannes Gutenberg-Universität, Mainz, standen mir in Deutschland beratend zur Verfügung. Darüberhinaus waren mir in verschiedenen Stadien der Arbeit eine Reihe von Personen und Institutionen behilflich: Frau Prof. Noelle-Neumann (Institut für Demoskopie, Allensbach), Herr Hildebrandt, Dr. Curtin (beide Institute for Social Research, University of Michigan, Ann Arbor), Herr Wolin, Dr. Anderson, Dr. Ashley, Prof. Ramanathan (alle Economics Departement, University of California, San Diego), Prof. Peisert (Zentrum I, Universität Konstanz).

Allen Genannten möchte ich meinen herzlichen Dank aussprechen.

Schließlich möchte ich dankbar die große Anteilnahme und Unterstützung erwähnen, die mir von meiner Familie zuteil wurde. Natürlich wäre diese Arbeit nicht möglich gewesen ohne die stets konstruktive Mitarbeit und das Verständnis meiner Ehefrau Renate. Ihr sowie meiner Tante Johanna Seilberger und meiner Schwester Erika Russ sei daher diese Arbeit gewidmet.

INHALTSVERZEICHNIS

	Seite
Vorbemerkung zur Terminologie und Notation	I
Problemstellung	IV
1 Ermittlung und theoretischer Hintergrund des ICS	1
11 Ermittlung des ICS	1
12 Die Beziehung des ICS zur Theorie der "Psychological Economics"	2
121 Die Theorie der "Psychological Economics"	3
122 Der ICS als Repräsentant der "Psychological Economics"	5
123 Zusammenfassung	6
2 Würdigung bisheriger Untersuchungen zur Beziehung des ICS zu ökonomischen Variablen	8
21 Die Ergebnisse im Überblick	8
22 Kritik an den bisherigen Untersuchungen	10
221 Behandlung der Autokorrelation der stochastischen Größe	10
2211 Exkurs: Zur Problematik von Autokorrelation in der sto- chastischen Größe eines linearen Regressionsmodells	10
2212 Die Untersuchungen von Juster (1969), Fair (1971) und Shapiro (1972) als Beispiele	15
2213 Die Kritik an der Behandlung der Autokorrelation der sto- chastischen Größe im Überblick	22
222 Wahl der Alternativmodelle	23
223 Methode der Modell-Spezifikation	27

3	Entwurf eines eigenen Analyse-Designs	28
4	Erster Teil der empirischen Analyse: Bewertung der Prognosegüte des ICS in einer Post-Sample-Periode	31
41	Vorstellung der den ICS einschließen- den Modelle	31
411	Mueller-Modell	32
412	Fair-Modell	35
42	Die "naiven" Modelle: univariate ARIMA- bzw. ARMA-Modelle	44
421	Allgemeines	45
422	Die Eignung univariater ARIMA- bzw. ARMA-Modelle als Maßstab	50
4221	Univariate ARMA-Prozesse als Repräsentationsform eines ökonometrischen Modells	50
4222	Die Prognosegüte univariater ARIMA- bzw. ARMA-Modelle im Vergleich zu der anderer univariater Modelle und der ökonometrischer Modelle	53
423	Die iterative Box/Jenkins-Strate- gie zur Identifikation und Schätzung univariater ARIMA- bzw. ARMA-Modelle	57
4231	Einleitung	57
4232	Die Identifikation der Ord- nung (p,d,q) bzw. (p,q) eines ARIMA- bzw. ARMA-Modells	59
42321	Die Autokorrelationen und partiellen Auto- korrelationen als Grundlage der Iden- tifikation	59

42322	Das Autokorrelogramm eines ARIMA-Prozesses für $d > 0$	62
42323	Das Autokorrelogramm ausgewählter ARMA- Prozesse	63
42324	Die statistischen Ei- genschaften der Schät- zungen der Autokorre- lationen und partiell- len Autokorrelationen	68
4233	Schätzung des ARIMA- bzw. ARMA-Modells	70
4234	Diagnostic Checks	72
4235	Zur Anwendung der iterativen Box/Jenkins-Strategie	75
424	Die Prognoseformel eines ARIMA- bzw. ARMA-Modells	77
43	Aufteilung der Beobachtungen auf Sample- und Post-Sample-Periode	79
44	Das Entscheidungskriterium der Progno- sebewertung	79
45	Die geschätzten Modelle und ihre Prog- noseformeln	83
451	Schätzung des Mueller-Modells	83
452	Identifikation und Schätzung des "naiven" Alternativmodells zum Mueller-Modell	88
4521	Identifikation	88
4522	Schätzung und Diagnostic Checks	95

453	Schätzung des Fair-Modells	97
454	Identifikation und Schätzung des "naiven" Alternativmodells zum Fair-Modell und des univariaten Modells für FEX_t	101
4541	Identifikation	101
4542	Schätzung und Diagnostic Checks	107
456	Die Prognoseformeln aller Modelle	109
4561	Die Prognoseformeln des Mueller-Modells und des "naiven" Alternativmodells	109
4562	Die Prognoseformeln des Fair-Modells, des "naiven" Alternativmodells und des univariaten Modells für FEX_t	114
46	Die Prognosegüte der Modelle	114
461	Die Prognosegüte des Mueller- Modells	114
4611	Analyse auf der objektiven Ebene	115
4612	Analyse auf der subjektiven Ebene	123
462	Die Prognosegüte des Fair-Modells	140
4621	Analyse auf der objektiven Ebene	140
4622	Analyse auf der subjektiven Ebene	144

47	Zusammenfassung der Ergebnisse des ersten Teils der empirischen Analyse	154
5	Zweiter Teil der empirischen Analyse: Spezifikation der Beziehungen des ICS zu ökonomischen Variablen	158
51	Der zeitreihenanalytische Ansatz als Grundlage der Analyse	158
52	Die Analogie zwischen ökonometrischen Modellen und Vektor-ARMA-Prozessen	162
53	Die iterative Strategie von Box/Jenkins und Granger/Newbold zur Identifikation und Schätzung der Transferfunktion-Form bivariater ARMA-Modelle	165
531	Einleitung	165
532	Kausalitätsanalyse	168
5321	Die zugrundeliegende Kausalitäts-Konzeption: Granger-Kausalität	168
5322	Das Kreuzkorrelogramm als Instrument der Kausalitätsanalyse	171
5323	Die Transformation zu weißem Rauschen vor Berechnung des Kreuzkorrelogramms	173
533	Die Identifikation der Transferfunktion-Form	180
534	Schätzung der Transferfunktion-Form	185

535	Diagnostic Checks	186
536	Zur Anwendung der iterativen Strategie von Box/Jenkins und Granger/Newbold	189
54	Die gewählte Untersuchungsperiode	190
55	Vorstellung der einbezogenen Variablen	190
56	Die Ergebnisse des zweiten Teils der empirischen Analyse	191
561	Identifikation und Schätzung der zur Transformation zu weißem Rauschen verwendeten Modelle	191
5611	Identifikation	191
56111	Identifikation der Ordnung d	193
56112	Identifikation der Ordnung (p,q)	210
5612	Schätzung und Diagnostic Checks	216
562	Kreuzkorrelogramm-Analyse	227
5621	Allgemeines	227
5622	Interpretation der Kreuzkorrelogramme	240
5623	Zusammenfassung der Ergebnisse der Kreuzkorrelogramm-Analyse	247
563	Identifikation und Schätzung der Transferfunktion-Form	248
5631	Allgemeines	248

5632	Identifikation	250
56321	Der ICS als unab- hängige Variable	250
56322	Der ICS als ab- hängige Variable	254
5633	Schätzung der Transfer- funktion-Form und Diag- nostic Checks	258
56331	Der ICS als unab- hängige Variable	259
56332	Der ICS als ab- hängige Variable	264
57	Zusammenfassung der Ergebnisse des zweiten Teils der empirischen Analyse	268
6	Abschließende Bemerkungen und Ausblick	271
	Zusammenfassung	281
	Literaturverzeichnis	285

Vorbemerkung zur Terminologie und Notation

1. In deutsch- wie englischsprachigen ökonomischen Lehrbüchern bezieht sich der Begriff "Prognose" ("prediction") im allgemeinen auf außerhalb der Schätzperiode befindliche Zeitpunkte.

Die Durchsicht der in die vorliegende Untersuchung einbezogenen englischsprachigen Literatur zur Beziehung des "Index of Consumer Sentiment" (ICS) zu ökonomischen Variablen läßt eine solche Zuordnung jedoch nicht immer erkennen. Begriffe wie "prediction", "forecasting" und "explanation" werden ohne festen Bezug darauf benutzt, ob die zu prognostizierenden Werte zur Schätzung herangezogen sind oder nicht. Gerade diese Information kann natürlich für die Beurteilung der Güte von Prognosen von erheblicher Bedeutung sein.

Um bei der Besprechung der Untersuchungen die Feststellung zu ermöglichen, auf welche Zeitpunkte sich der jeweils gewählte Begriff bezieht, ist eine Unterscheidung zwischen "Sample-Periode" und "Post-Sample-Periode" getroffen. In der Sample-Periode liegen die für die Schätzung eines Modells verwendeten Beobachtungen; die Post-Sample-Periode umfaßt nur solche Beobachtungen, die nicht auch bei der Schätzung beteiligt sind. Diese Unterscheidung entspricht auch dem üblichen Gebrauch in der englischsprachigen ökonomischen Literatur.

2. "Diskretionäre Konsumausgaben" ist die wörtliche Übertragung des englischen Ausdrucks "discretionary consumption expenditures". Mit dieser Wortwahl ist bewußt eine

Verwechslung mit Begriffen wie "langlebige Gebrauchsgüter", die in Veröffentlichungen des Statistischen Bundesamtes eine fest umgrenzte Bedeutung besitzen, vermieden. Sofern in den empirischen Teilen dieser Untersuchung die Variable "diskretionäre Konsumausgaben" verwendet wird, ist die in dem jeweils benutzten statistischen Quellenwerk aufgeführte Definition wiedergegeben.

3. In der englischsprachigen ökonometrischen Literatur wird in Anlehnung an naturwissenschaftliche Begriffssysteme die stochastische Größe¹⁾ eines linearen Regressionsmodells häufig mit "noise" und das Bildungsgesetz der stochastischen Größe - z.B. in der Form eines autoregressiven Prozesses erster Ordnung - mit "noise model" bezeichnet. Wegen seiner Anschaulichkeit sowie der Schwierigkeit, eine angemessene deutsche Übersetzung zu finden, wird in der vorliegenden Untersuchung der Ausdruck "Noise-Modell" zur Kennzeichnung der parametrischen Repräsentation des Bildungsgesetzes der stochastischen Größe eines linearen Regressionsmodells verwendet.²⁾

4. Im folgenden ist die Bedeutung einiger häufig wiederkehrender Abkürzungen und Ausdrücke erläutert.

DW	Durbin-Watson-Statistik;
GLS	Generalized least squares;
MSE	Mean squared error;
OLS	Ordinary least squares;
R^2	Quadrat des multiplen Korrelationskoeffizienten;

1) Der Begriff "stochastische Größe" bezieht sich nicht auf die abhängige Variable eines linearen Regressionsmodells - auch sie ist stochastischer Natur -; er ist im Sinne der für Gleichung (2.1) verwendeten Terminologie zu verstehen.

2) Das "Noise-Modell" entspricht einem univariaten ARIMA-Modell der stochastischen Größe. Zu univariaten ARIMA-Modellen vgl. S. 44 ff.

III

$\frac{\partial L}{\partial \lambda}$	Erwartungstreuer multipler Determinationskoeffizient;				
sp	Spur einer Matrix;				
2SLS	Two-stage least squares;				
$\underline{A}$	Matrix oder Vektor;				
$\underline{A}'$	Transponierte Matrix von $\underline{A}$;				
$ \underline{A} $	Determinante von $\underline{A}$;				
$\underline{A}^*$	Matrix der Adjunkten von $\underline{A}$;				
$ e $	Absoluter Wert des Skalars e ;				
$d_{tt'}$	Kronecker Delta, mit <table data-bbox="528 541 870 623"> <tr> <td>$d_{tt'} = 1$</td><td>für $t = t'$</td></tr> <tr> <td>$d_{tt'} = 0$</td><td>für $t \neq t'$.</td></tr> </table>	$d_{tt'} = 1$	für $t = t'$	$d_{tt'} = 0$	für $t \neq t'$.
$d_{tt'} = 1$	für $t = t'$				
$d_{tt'} = 0$	für $t \neq t'$.				

Problemstellung

Der "Index of Consumer Sentiment" (ICS) ist in einer größeren Anzahl von Untersuchungen als Instrument zur Prognose diskretionärer Konsumausgaben in den USA verwendet.¹⁾

Die nachfolgende Analyse bemüht sich unter kritischer Würdigung dieser Untersuchungen und unter Vorlage eigener Ansätze um die Beantwortung der Fragen:

- Ist die Berücksichtigung des ICS in Modellen zur Prognose US-amerikanischer diskretionärer Konsumausgaben tatsächlich zu rechtfertigen?
- In welcher Form sollten Modelle zur Prognose US-amerikanischer diskretionärer Konsumausgaben, in die der ICS integriert wird, spezifiziert werden?

Bei der Beantwortung dieser Fragen ist auch dem Problem der Prognostizierbarkeit des ICS selbst Aufmerksamkeit geschenkt. Die Bedeutung der Prognostizierbarkeit des ICS für die Prognose diskretionärer Konsumausgaben²⁾ läßt sich am allgemeinen Fall wie folgt begründen.

Es sei Y_{t+h} in Periode t zu prognostizieren aufgrund der Prognoseformel

$$Y_t = c(B)X_t$$

wobei

-
- 1) Beschreibungen solcher Untersuchungen finden sich in Abschnitt 2.
 - 2) Hier und im folgenden ist der ausdrückliche Bezug auf US-amerikanische Verhältnisse unterlassen.

$$c(B) = \sum_{j=1}^m B^j$$

B Lag-Operator

Y_t könnte z.B. diskretionäre Konsumausgaben und X_t den ICS bezeichnen.

Für die Prognose von Y_{t+h} ist die Kenntnis von X_{t+h-1} , X_{t+h-2} , ..., X_{t+h-m} Voraussetzung. Wenn unterstellt wird, der in Periode t letzte verfügbare Wert sei X_t , müssen alle X_{t+k} , $k = 1, \dots, (h-1)$, selbst prognostiziert werden. Hierzu sind Annahmen über den Erzeugungsmechanismus der im Verhältnis zu Y_t unabhängigen Variablen X_t notwendig.¹⁾

1) Vgl. auch Fair (1971), S. 3: "For a forecasting model, the exogenous variables ... must be chosen with the restriction that they be at least no more difficult to forecast than the variables they are designed to explain. Since the values of the exogenous variables in a model must be forecast ahead of the overall forecast, no forecasting accuracy is likely to be gained by including in the model exogenous variables that are to begin with as difficult to forecast as the endogenous variables themselves."

1 Ermittlung und theoretischer Hintergrund des ICS

11 Ermittlung des ICS

Der ICS basiert auf vierteljährlichen Bevölkerungsumfragen des Survey Research Center, die sich an ca. 1500 Privathaushalte der USA, unter Ausschluß von Hawai und Alaska, richten.¹⁾

Er wird aus den Antworten auf fünf Fragen berechnet:

Nummer der
Frage²⁾

1. "Would you say that you (and your family) are better off or worse off financially than you were a year ago?"
2. "Now looking ahead - do you think that a year from now you (and your family) will be better off financially, or worse off, or just about the same as now?"
3. "Now turning to business conditions in the country as a whole - do you think that during the next 12 months we'll have good times financially, or bad times, or what?"
4. "Looking ahead, which would you say is more likely - that in the country as a whole we'll have continuous good times during the next 5 years or so, or that we will have periods of widespread unemployment or depression, or what?"

-
- 1) Für eine Beschreibung der verwendeten Interview- und Stichprobentechnik vgl. Curtin (1976), S. 221 ff.
 - 2) Die Nummern müssen nicht mit denen in den Bevölkerungsumfragen des Survey Research Center übereinstimmen. Sie dienen nur zur Referenz in anderen Teilen der Untersuchung.

5. "About the big things people buy for their homes - such as furniture, refrigerator, stove, television and things like that. Generally speaking, do you think now is a good or a bad time for people to buy major household items?"

Zur Berechnung des ICS wird zunächst für jede Frage getrennt die Differenz zwischen den "optimistischen" und "pessimistischen" Antworten (in Prozent) gebildet und jeweils zu 100 addiert. "Neutrale" Antworten werden nicht berücksichtigt.¹⁾ Der tatsächlich ausgewiesene Indexwert ist der Durchschnitt über die fünf Fragen, adjustiert zur Basis 1966.1 = 100.²⁾

Dieses Berechnungsverfahren unterscheidet sich von früheren Ansätzen in zwei Punkten: einmal ist die Basis von 1956.3 = 100 auf 1966.1 = 100 verschoben, zum anderen ist die Durchschnittsbildung verändert. Es wurde erst das Ergebnis jeder einzelnen Frage adjustiert und dann ein Durchschnitt über die fünf Fragen gebildet, während bei dem oben beschriebenen Verfahren zunächst der Durchschnitt errechnet und dann adjustiert wird.

In den Jahren bis 1960 führte das Survey Research Center nicht für alle Quartale Bevölkerungsumfragen durch; der ICS weist daher für diese Zeit einige Lücken auf. Diese Lücken sind bei der vom Survey Research Center ausgewiesenen Serie durch lineare Interpolation beseitigt.

12 Die Beziehung des ICS zur Theorie der "Psychological Economics"

- 1) Das gleiche Ergebnis wird erzielt, wenn die Prozentwerte der Antwortkategorien die folgenden Punktwerte erhalten: "optimistische" Antworten = 2, "neutrale" Antworten = 1, "pessimistische" Antworten = 0. Zu Einzelheiten der Berechnung vgl. Curtin (1976), S. 2.
- 2) Die ICS-Reihe ist somit durch Multiplikation mit einer Konstanten transformiert; diese Transformation läßt die autokorrelative Struktur der Reihe unverändert.

121 Die Theorie der "Psychological Economics"

1. Die Beziehung des ICS zu ökonomischen Variablen, insbesondere seine Eignung zur Prognose diskretionärer Konsumausgaben, ist mithilfe der von George Katona entwickelten "Psychological Economics" theoretisch begründet.¹⁾

Die Lehren der "Psychological Economics" sind in den Schriften Katonas ausführlich dargestellt. Die folgende kurze Zusammenfassung,²⁾ die für das Verständnis der Eingliederung des ICS in das Beziehungsgefüge ökonomischer Variablen von Bedeutung ist, stützt sich auf sein 1975 erschienenes Werk "Psychological Economics", das die wesentlichen Teile seiner Hauptwerke³⁾ enthält.

2. Als Grundthese der "Psychological Economics" ist die Ansicht zu betrachten, diskretionäre Konsumausgaben seien nicht nur von der Kauffähigkeit, sondern auch von der Kaufwilligkeit der Konsumenten bestimmt: "Consumers' discretionary demand is a function both of ability and willingness to buy".⁴⁾

Nach Katona setzt die im Vergleich zu der Zeit vor dem zweiten Weltkrieg verbesserte wirtschaftliche Situation breite Bevölkerungskreise in die Lage, über größere Teile des Einkommens frei zu verfügen.⁵⁾

Die so gewonnene Entscheidungsfreiheit der Konsumenten läßt sich in besonderem Maße bei diskretionären Konsumausgaben verwirklichen. Diskretionäre Konsumausgaben sind

1) Hier und im folgenden ist der Begriff "Psychological Economics" ausschließlich im Sinne der Arbeiten Katonas zu verstehen.

2) Geraffte Darstellungen der "Psychological Economics" finden sich auch bei Katona (1957), Katona (1967a), Katona (1967b), Katona (1968), Katona (1972), Katona (1976), Katona/Mueller (1961).

3) Katona (1951), Katona (1960), Katona (1964).

4) Katona (1975), S. 82. Vgl. auch ibid., S. 11.

5) Vgl. Katona (1975), S. 19 u. 32.

nicht gewohnheitsgesteuert, sie sind nicht unbedingt lebensnotwendig, und sie werden in der Regel nur nach gründlicher Planung getätigt.¹⁾

Unter den Bestimmungsgrößen diskretionärer Konsumausgaben kommt also wegen der relativ hohen Massenkaufkraft und der spezifischen Eigenschaften diskretionärer Konsumausgaben der Kaufwilligkeit - "willingness to buy" - eine besondere Bedeutung zu.

3. Nach Katona kann die Beziehung zwischen der Kaufwilligkeit und den diskretionären Konsumausgaben durch die psychologische Konzeption der "intervening variables" beschrieben werden: "The basic scheme of psychological studies is:

Stimulus - Organism - Response
or
Change in environment - Intervening Variables -
Overt Behavior."²⁾

Als "intervening variables" bezeichnet Katona Motive, Einstellungen und Erwartungen ("Motives, attitudes and expectations"³⁾).⁴⁾ Diese - von Katona im Zusammenhang mit der Beschreibung des Konsumentenverhaltens summarisch als "consumer sentiment" bezeichneten Konzepte - sind als wichtige Indikatoren diskretionärer Konsumausgaben anzusehen.⁵⁾ Dagegen ist eine Prognostizierbarkeit der "in-

1) S. Katona (1975), S. 30: "Discretionary expenditures ... are not inevitable necessary, not habitual, and not made on the spur of the moment". Vgl. auch ibid., S. 29.

2) Ibid., S. 44.

3) Ibid.

4) S. ibid.: "The terms used and their exact definitions are not very important".

5) Vgl. ibid., S. 11. S. auch Katona (1976), S. 211: "Discretionary expenditures ... represent the response most influenced by the intervening variables ... This underlying theory enables us to view consumer sentiment as an anticipatory variable which may be used for forecasting ...".

tervening variables" selbst nach Katona nicht ohne weiteres möglich.¹⁾

4. Die "intervening variables" sind nach Katona durch repräsentative Bevölkerungsumfragen, wie sie vom Survey Research Center durchgeführt werden, zu messen.²⁾

122 Der ICS als Repräsentant der "Psychological Economics"

1. Katona hat die Beziehung zwischen den Inhalten der "Psychological Economics" und dem ICS häufig betont.³⁾ Dabei beruht die Eignung des ICS, als Repräsentant der "Psychological Economics" zu fungieren, auf zwei Aspekten:

- der Information, die in den zur Berechnung des ICS verwendeten Fragen enthalten ist;
- den Vorteilen, die aus der Kombination einzelner Einstellungsmaße resultieren.

Die fünf Fragen, die zur Berechnung des ICS herangezogen werden, lassen sich inhaltlich drei Komplexen zuordnen: Einstellungen zur persönlichen finanziellen Sphäre (erste und zweite Frage), Einschätzung der kurz- und mittelfristigen Entwicklung der Gesamtwirtschaft (dritte und vierte Frage) und Einschätzung der Marktlage für diskretionäre Konsumgüter (fünfte Frage). Diese drei Komplexe werden von Katona als wesentlich für die Bestimmung der Kaufwilligkeit bezeichnet.⁴⁾

1) Vgl. Katona (1976), S. 205.

2) S. Katona (1975), S. 79: "The most important clues about what makes consumers become more optimistic, or more pessimistic, at a given time are derived from the interviewing methods used by the Survey Research Center".

3) S. z.B. Katona (1976), S. 212: "... the predictive value of the Index can be viewed as evidence supporting the theory of psychological economics". Vgl. auch Katona (1968), S. 23, Katona (1975), S. 11, Katona/Mueller (1961), S. 176.

4) Vgl. Katona (1974), S. 74 ff.

Die Kombination der fünf, auf die Erfassung jeweils spezieller Einstellungen und Erwartungen gerichteter Fragen entspricht nach Katona den Aussagen der "Gestalt-Theorie", die eine der Grundlagen der "Psychological Economics" ist.¹⁾

2. Obwohl der ICS also vor dem Hintergrund der "Psychological Economics" zu interpretieren ist, dürfen nach Ansicht von Katona und seiner Mitarbeiter am Survey Research Center die Grenzen des ICS nicht übersehen werden, die durch die Unmöglichkeit, der Vieldimensionalität von Einstellungen und Erwartungen in einem einzelnen Index vollständig Rechnung zu tragen, gezogen sind.²⁾

123 Zusammenfassung

Die bisherigen Ausführungen zur Beziehung des ICS zur Theorie der "Psychological Economics" lassen sich wie folgt zusammenfassen:

- Der ICS wird als ein wertvoller Indikator der Stimmungen, Erwartungen, etc., der Konsumenten in bezug auf die wirtschaftliche Lage bezeichnet. Einschränkungen der Aussagefähigkeit des ICS sind jedoch wegen der Vieldimensionalität der psychologischen Determinanten des Konsumverhaltens angezeigt.
- Die Hypothese der "Psychological Economics", meßbare psychologische Variablen beeinflussen das Konsumentenverhalten, impliziert die Annahme, der ICS sei zur Prognose diskretionärer Konsumausgaben geeignet.

1) Vgl. Katona (1957), S. 42, Katona/Mueller (1956), S. 91.
 2) Vgl. Katona/Mueller (1956), S. 105, Survey Research Center (1963), S. 125, Katona (1964), S. 37 f., Curtin (1973), S. 253.

- Eine Prognostizierbarkeit des ICS ist nicht zu erwarten.

2 Würdigung bisheriger Untersuchungen zur Beziehung des ICS zu ökonomischen Variablen

Da die Theorie der "Psychological Economics" keine ausreichenden Hinweise auf die Spezifikation von Modellen gibt, die die Beziehung des ICS zu ökonomischen Variablen beschreiben,¹⁾ ist der Test von Hypothesen im statistischen Sinne erschwert. Letztlich basiert damit auch eine empirisch belegte Aussage über die Eignung des ICS zur Prognose diskretionärer Konsumausgaben - hieraus leitet sich im wesentlichen die Begründung für seine Ermittlung her - auf der jeweils gewählten Spezifikation.²⁾

Nachfolgend sind die wesentlichen Ergebnisse von Untersuchungen berichtet, in denen der ICS als unabhängige Variable zur Prognose diskretionärer Konsumausgaben und als abhängige Variable, erklärt durch ökonomische Variablen, auftritt. Die Ergebnisse dieser Untersuchungen könnten zumindestens als Hinweise auf die Prognostizierbarkeit diskretionärer Konsumausgaben durch den ICS sowie auf die Prognostizierbarkeit des ICS selbst verstanden werden.

Anschließend ist kritisch zu den Besonderheiten der jeweiligen verwendeten Analyse-Designs Stellung genommen.

21 Die Ergebnisse im Überblick

1. Die Fähigkeit des ICS, einen nützlichen Beitrag zur Prognose diskretionärer Konsumausgaben zu erbringen, wird in den Untersuchungen von Mueller (1963), Friend/Adams

- 1) S. auch Katona (1972), S. 579: "We ... failed ... to specify a complete mathematical model to be used for purposes of prediction".
- 2) S. ibid., S. 580: "... the net contribution of the Index to forecasting, that is, its contribution beyond that of other variables included in an equation, depends greatly on the specifications set up for the regression equations used."

(1964), Suits/Sparks (1965), Maynes (1967), Juster (1969), Burch/Stekler (1969), Fair (1971), Juster/Wachtel (1972a), Juster/Wachtel (1972b) und Adams/Klein (1972) überwiegend bestätigt.¹⁾ Nur die Ergebnisse von Hymans (1970) geben keinen Hinweis auf die Verbesserung der Prognose diskretionärer Konsumausgaben durch die Berücksichtigung des ICS.²⁾

2. In den Untersuchungen von Adams/Green (1965), Suits/Sparks (1965) und Adams/Klein (1972) wird die Ansicht vertreten, der ICS sei durch ökonomische Variable gut prognostizierbar.³⁾ Nur Mueller (1963) hält den ICS für weitgehend unabhängig von ökonomischen Variablen.

- 1) S. z.B. Mueller (1963), S. 915: "... discretionary spending by consumers is determined to a large extent by income level and the state of consumer optimism and confidence. The Index ... does consistently well in the time series test ..."; Friend/Adams (1964), S. 1004: "This study confirms that consumer attitudes ... give advanced insight into the number of cars purchased or the amount of money spent on them ..."; Suits/Sparks (1965), S. 206: "The consumer attitudes index makes a significant contribution to the automobile equation ..."; Juster (1969), S. 215: "... attitudes generally make a significant contribution to the explanation of variance in either automobile or durable goods purchases during all the fit periods examined ..."; Fair (1971), S. 241: "... the Michigan Survey Research center index of consumer sentiment was significant in explaining short-run consumer behavior ..."; Juster/Wachtel (1972a), S. 569: "... lagged attitudes clearly add to the explanatory power ... both for automobiles and total durables ...".
- 2) S. Hymans (1970), S. 182: "... The sentiment index is clearly the 'weak sister' in the equation ...".
- 3) S. z.B. Adams/Green (1965), S. 279: "We have been able to show that attitudes are highly correlated with other cyclical indicators, particularly those relating to employment conditions ... The analysis shows little evidence that there is anything in the attitudes that is not by and large covered by other variables ..."; Shapiro (1972), S. 391: "... other readily available data on income, inflation rates, and stock prices could be substituted for the survey results in preparing short-term forecasts of consumer discretionary spending."

22 Kritik an den bisherigen Untersuchungen

Die Kritik an den zitierten Untersuchungen richtet sich auf drei Bereiche:¹⁾

- Behandlung der Autokorrelation der stochastischen Größe;
- Wahl der Alternativmodelle;
- Methode der Modell-Spezifikation.

221 Behandlung der Autokorrelation der stochastischen Größe

Die Behandlung der autokorrelativen Struktur der stochastischen Größe eines linearen Regressionsmodells ist ein zentraler Kritikpunkt an den vorliegenden Untersuchungen. Die hier wesentlichen Aspekte seien am allgemeinen Fall kurz dargestellt, um die weiteren Ausführungen von Wiederholungen freizuhalten.

2211 Exkurs: Zur Problematik von Autokorrelation in der stochastischen Größe eines linearen Regressionsmodells

1. Es sei das folgende lineare Regressionsmodell unterstellt:

$$(2.1) \quad \underline{Y} = \underline{Xb} + \underline{U}$$

1) Der Aspekt der Multikollinearität ist hier nicht berücksichtigt, da er für Prognosezwecke von geringerer Bedeutung ist.

wobei

$$\begin{aligned}\underline{Y}' &= \begin{bmatrix} Y_1 & Y_2 & \dots & Y_T \end{bmatrix} \\ \underline{X} &= \begin{bmatrix} 1 & X_{21} & \dots & X_{k1} \\ 1 & X_{22} & \dots & X_{k2} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ 1 & X_{2T} & \dots & X_{kT} \end{bmatrix} \\ \underline{b}' &= \begin{bmatrix} b_1 & b_2 & \dots & b_k \end{bmatrix} \\ \underline{U}' &= \begin{bmatrix} U_1 & U_2 & \dots & U_T \end{bmatrix}\end{aligned}$$

$$\begin{aligned}E(\underline{U}) &= \underline{0} \\ E(\underline{U}\underline{U}') &= \underline{V}\end{aligned}$$

$\underline{Y}$ ist also der $(T \times 1)$ -Vektor der abhängigen Variablen, $\underline{X}$ ist die $(T \times k)$ -Matrix der k unabhängigen Variablen, wobei $X_{1t} = 1$ für alle t , $\underline{b}$ ist der $(k \times 1)$ -Vektor der Parameter, wobei b_1 die Konstante des Modells repräsentiert, $\underline{U}$ ist der $(T \times 1)$ -Vektor der stochastischen Größe, und $\underline{V}$ ist eine positiv definite Matrix der Ordnung T . Es sei angenommen, die unabhängigen Variablen seien nicht-stochastisch und $\underline{X}$ habe Rang k , mit $k < T$, die U_t besäßen zeitinvariante Dichtefunktionen und $\underline{V}$ sei keine Diagonalmatrix. Die letztgenannte Bedingung sichert die Existenz von Autokorrelation zwischen den U_t .

2. Unter den genannten Bedingungen ist die OLS-Schätzung $\underline{b}^{OLS}$ des Parameter-Vektors $\underline{b}$ zwar konsistent, jedoch ineffizient im Vergleich zu der GLS-Schätzung $\underline{b}^{GLS}$. Es gilt nämlich:¹⁾

1) Vgl. Theil (1971), S. 247, Johnston (1972), S. 246.

$$(2.2) \quad \text{var}(\underline{b}^{\text{OLS}}) = (\underline{X}'\underline{X})^{-1}\underline{X}'\underline{V}\underline{X}(\underline{X}'\underline{X})^{-1}$$

$$(2.3) \quad \text{var}(\underline{b}^{\text{GLS}}) = (\underline{X}'\underline{V}^{-1}\underline{X})^{-1}$$

und $\text{var}(\underline{b}^{\text{OLS}})$ übersteigt $\text{var}(\underline{b}^{\text{GLS}})$ um eine positiv definit Matrix.¹⁾

Die bei der OLS-Schätzung ausgewiesene Varianz-Kovarianz-Matrix von $\underline{b}^{\text{OLS}}$ unterschätzt in aller Regel die wahren Varianzen und Kovarianzen der Elemente von $\underline{b}^{\text{OLS}}$.²⁾

Die OLS-Schätzung der Varianz der stochastischen Größe ist ebenfalls mit einem Bias versehen. Eine erwartungstreue Schätzung ist:³⁾

$$(2.4) \quad (\underline{e}'^{\text{OLS}}\underline{e}^{\text{OLS}})(T - \text{sp}(\underline{X}(\underline{X}'\underline{X})^{-1}\underline{X}'\underline{V}))^{-1}$$

Die OLS-Schätzung lautet dagegen:

$$(2.5) \quad (\underline{e}'^{\text{OLS}}\underline{e}^{\text{OLS}})(T - k)^{-1}$$

wobei

$$(2.6) \quad \underline{e}^{\text{OLS}} = \underline{Y} - \underline{X}\underline{b}^{\text{OLS}}$$

$\text{sp} = \text{Spur}$

Im allgemeinen gilt, wenn die U_t autokorreliert sind⁴⁾,

$$(2.7) \quad k < \text{sp}(\underline{X}(\underline{X}'\underline{X})^{-1}\underline{X}'\underline{V})^{-1}$$

1) Vgl. Theil (1971), S. 247, Malinvaud (1970), S. 524 ff.

2) Vgl. Theil (1971), S. 248.

3) Vgl. Johnston (1972), S. 248, Theil (1971), S. 256.

4) Vgl. Theil (1971), S. 256 f.

so daß OLS die Varianz der stochastischen Größe unterschätzt, mithin ein zu positives Bild von der Erklärungskraft des Modells zeichnet.

3. Die üblichen Tests der Signifikanz der Koeffizienten in $\underline{b}^{OLS}$ sind nicht anwendbar, wenn die U_t autokorreliert sind. Unter der Null-Hypothese

$$H_0: b_2 = b_3 = \dots = b_k = 0$$

folgt die Statistik

$$(2.8) \quad F^* = \frac{T - k}{k - 1} \frac{R^2}{1 - R^2}$$

nämlich nur dann einer F-Verteilung mit $(k - 1)$ und $(T - k)$ Freiheitsgraden, wenn keine Autokorrelation in den U_t existiert.¹⁾

4. Unter den getroffenen Annahmen ist nach Goldberger die beste lineare biasfreie Prognose P_{opt} des in der Post-Sample-Periode befindlichen Wertes Y_{T+1} durch die folgende Prognoseformel bestimmt:²⁾

$$(2.9) \quad P_{opt} = \underline{X}_{T+1} \underline{b}^{GLS} + \underline{W}' \underline{V}^{-1} \underline{e}^{GLS}$$

wobei

$$\underline{X}'_{T+1} = \begin{bmatrix} 1 & X_{2,T+1} & \dots & X_{k,T+1} \end{bmatrix}$$

$$\underline{W} = E(U_{T+1} \underline{U}) = \begin{bmatrix} E(U_{T+1} U_1) & \dots & E(U_{T+1} U_T) \end{bmatrix}$$

$$\underline{e}^{GLS} = \underline{Y} - \underline{X} \underline{b}^{GLS}$$

1) Vgl. Johnston (1972), S. 249, Rowley (1973), S. 35.

2) Vgl. Goldberger (1962), Johnston (1972), S. 212 f., Malinvaud (1970), S. 535 ff.

Bei der Prognose von Y_{T+1} sind also der Vektor der GLS-Schätzungen $\underline{b}^{GLS}$, die autokorrelative Struktur der U_t - repräsentiert durch $\underline{V}$ - und der GLS-Residual-Vektor $\underline{e}^{GLS}$ zu berücksichtigen, wenn σ_p^2 minimiert werden soll, wobei

$$(2.10) \quad \sigma_p^2 = E(P - Y_{T+1})^2$$

P = Prognose von Y_{T+1}

5. Eine Monte Carlo-Studie von Granger/Newbold¹⁾ gibt Aufschluß über die Eigenschaften von OLS-Schätzungen für den Fall stochastischer Regressoren. Granger/Newbold erzeugten unabhängige Reihen, die jeweils stark positiv autokorreliert waren. Aufgrund von OLS-Regressionen ergeben sich die folgenden Schlußfolgerungen:²⁾

- Der DW-Test zeigt jeweils deutlich Autokorrelation in den OLS-Residuen auf; d.h. die Autokorrelation der Reihen spiegelt sich in den OLS-Residuen wider.
- Die (wahre) Nullhypothese der Unabhängigkeit der Reihen ist aufgrund des (bewußt fälschlich angewendeten) F-Tests überwiegend abzulehnen.³⁾
- $\bar{R}^2$ nimmt häufig hohe Werte - bis zu .70 - an.

6. Es ist üblich, die Existenz von Autokorrelation erster Ordnung in der stochastischen Größe eines linearen Regressionsmodells mithilfe der DW-Statistik zu testen. Die Teststärke der DW-Statistik sinkt jedoch ab, wenn sich unter den Regressoren die verzögerte abhängige Variable

1) Vgl. Granger/Newbold (1974).

2) Vgl. ibid., S. 116.

3) Wie oben ausgeführt, ist der F-Test nur anwendbar, wenn die stochastische Größe weißes Rauschen ist.

befindet.¹⁾ In diesem Fall besitzt die DW-Statistik einen asymptotischen Bias gegen zwei.²⁾

2212 Die Untersuchungen von Juster (1969), Fair (1971)
und Shapiro (1972) als Beispiele

Die Kritik an der Behandlung der autokorrelativen Struktur der stochastischen Größe läßt sich beispielhaft für die Untersuchungen von Juster (1969), Fair (1971) und Shapiro (1972), die jeweils unterschiedliche Analyse-Designs verwenden, formulieren.

1. Juster widmet der Sample- und Post-Sample-Bewertung eines bei Mueller³⁾ erstmals aufgeführten Modells - im weiteren als "Mueller-Modell" bezeichnet - relativ breiten Raum.⁴⁾ Das Mueller-Modell ist wie folgt spezifiziert:

$$(2.11) \quad CDM_{t+1,t+2} = c_0 + c_1 YDM_{t-2,t-1} + c_2 ICS_t + U_{t+1,t+2} \\ (CAM_{t+1,t+2})$$

wobei

$CDM_{t+1,t+2}$	Consumer durable goods expenditures in quarters $(t + 1)$ and $(t + 2)$;
$CAM_{t+1,t+2}$	Consumer expenditures on motor vehicles and parts in quarters $(t + 1)$ and $(t + 2)$;

1) Vgl. Nerlove/Wallis (1966), S. 236.

2) S. ibid., S. 237: " ... there is always a presumption against finding evidence of serial correlation, no matter what the true situation may be. Thus, a "non-significant" value of the Durbin-Watson statistic does not preclude the possibility that ordinary least squares estimates are inconsistent when lagged endogenous variables are present". Vgl. auch Johnston (1972), S. 309 ff.

3) Vgl. Mueller (1963).

4) Das Mueller-Modell ist auch von Maynes (1967) und Burch/Stekler (1969) analysiert.

$YDM_{t-2,t-1}$	Disposable personal income in quarters $(t - 2)$ and $(t - 1)$;
ICS_t	ICS in quarter t ;
$U_{t+1,t+2}$	Stochastische Größe in den Quartalen $(t + 1)$ und $(t + 2)$. ¹⁾

Die in Geldeinheiten ausgedrückten Variablen sind für Preisveränderungen, die Zahl der Familien sowie saisonbereinigt.

Mithilfe des in unterschiedlichen Sample-Perioden geschätzten Mueller-Modells sind Post-Sample-Prognosen erstellt, deren Güte an der von Prognosen eines "naiven" autoregressiven Modells gemessen wird.²⁾

Einige wesentliche Ergebnisse der Schätzung des Mueller-Modells sind in Tabelle 1 wiedergegeben.

Bei der Kritik an Justers Untersuchung muß zunächst auf die hohe Autokorrelation verwiesen werden, die in den Residuen der OLS-Regressionen verbleibt (vgl. die DW-Statistik in Tabelle 1). Die Instabilität der t -Werte (vgl. Tabelle 1) kann wegen der Konsequenzen von OLS-Regressionen angesichts autokorrelierter stochastischer Größe nicht überraschen. Juster hätte entweder ein Schätzverfahren verwenden sollen, das der autokorrelativen Struktur der stochastischen Größe Rechnung trägt, oder er hätte auf die Fragwürdigkeit der für die t -, F -Statistik und $\bar{R}^2$ ausgewiesenen Werte eingehen müssen.

1) Die in Geldeinheiten ausgedrückten Variablen sowie die stochastische Größe sind also gleitende Halbjahreswerte.

2) Zur Kritik an der Spezifikation des von Juster gewählten "naiven" Modells vgl. Abschnitt 222.

Tabelle 1

Zusammenfassung einiger bei Juster (1969) ausgewiesener
Ergebnisse

Abhängige Variable	Sample- Periode	t-Statistik der Parame- ter-Schätzg. des ICS	$\bar{R}^2$	DW
Autoaus- gaben	1953.2 - 62.2	4.7	.51	1.47*
	- 63.3	5.8	.67	1.44*
	- 64.3	6.2	.76	1.30**
	- 66.1	7.3	.89	1.35*
	- 67.2	8.0	.92	1.29**
	1955.3 - 63.3	5.6	.65	1.61*
	1957.1 - 64.3	4.0	.84	1.34*
	1959.3 - 66.1	1.3	.92	1.29**
	1961.2 - 67.2	7.2	.95	1.08**
Gebrauchs- güterausga- ben	1953.2 - 62.2	5.0	.64	1.32*
	- 63.3	6.1	.81	1.27*
	- 64.3	5.6	.84	.86**
	- 66.1	6.9	.93	.92**
	- 67.2	7.2	.96	.86**
	1955.3 - 63.3	6.4	.80	1.45*
	1957.1 - 64.3	2.9	.90	.84**
	1959.3 - 66.1	.9	.97	.94**
	1961.2 - 67.2	5.9	.97	.97**

* DW indiziert signifikante Autokorrelation erster
Ordnung in den Residuen;

** DW liegt in der Unbestimmtheits-Region.

Da Juster die Zeitreihennatur der stochastischen Größe bei der Schätzung des Mueller-Modells außer acht läßt, sind auch die Post-Sample-Prognosen wegen der Nichtberücksichtigung des Noise-Modells ineffizient. Wie aufgrund dieses Vorgehens zu erwarten, sind die Prognosefehler des Mueller-Modells in der Post-Sample-Periode autokorreliert; dies läßt bereits die visuelle Inspektion der von Juster ausgewiesenen Graphiken erkennen.¹⁾

2. Fair untersucht die Bedeutung des ICS für diverse Kategorien von Konsumausgaben im Rahmen eines ökonometrischen Modells; der ICS ist als exogene Variable klassifiziert. Die strukturellen Gleichungen dieses ökonometrischen Modells basieren auf Vergleichen unterschiedlicher Spezifikationen, wobei als Kriterien die Signifikanz der Parameter-Schätzungen und $\bar{R}^2$ verwendet sind. Bei der Schätzung der Gleichungen unterstellt Fair die Existenz eines autoregressiven Prozesses erster Ordnung in der stochastischen Größe.²⁾ Als das Modell mit der besten Erklärungskraft für Gebrauchsgüterausgaben in der Sample-Periode von 1956.1 - 1969.4 nennt Fair:³⁾

$$(2.12) \quad CDF_t = -25.43 + .103 \overline{GNP}_t + .110 ICS_{t-1} + .092 ICS_{t-2} \\ (4.22) \quad (39.78) \quad (1.88) \quad (1.54)$$

$$R^2 = .69$$

1) Vgl. Juster (1969), S. 227 u. 230.

2) Das angewandte Schätzverfahren ist eine Version des 2SLS-Verfahrens: "It is essentially a combination of the standard two-stage least squares technique for dealing with simultaneous equation bias and the Cochrane-Orcutt iterative technique for dealing with serially correlated errors". Fair (1971), S. 19.

3) Vgl. ibid., S. 32. In Klammern: t-Statistik.

Legende:

$CD\bar{F}_t$	Consumer durable goods expenditures in quarter t;
GNP_t	Gross national product in quarter t;
ICS_t	ICS in quarter t.

R_{Δ}^2 ist das Quadrat des multiplen Koerrelationskoeffizienten zwischen den ersten Differenzen von CD_t und den ersten Differenzen der Linearkombination der unabhängigen Variablen. Der Strich über GNP_t weist daraufhin, daß GNP_t mithilfe des 2SLS-Verfahrens geschätzt ist.¹⁾ Die in Geldeinheiten ausgedrückten Variablen sind saisonal, nicht jedoch für Preisveränderungen adjustiert.

Die oben ausgewiesene Gleichung ist ein Bezugspunkt späterer Ausführungen. Sie wird im folgenden als "Fair-Modell" bezeichnet.²⁾

In einer Gegenüberstellung mit Post-Sample-Prognosen des OBE-³⁾ und des Wharton-Modells - beides erheblich aufwendigere Modelle als Fairs ökonometrisches Modell - schneidet nach Fair das eigene ökonometrische Modell besser ab.⁴⁾

Fairs Untersuchung hebt sich von der Mehrzahl der übrigen Analysen zur Beziehung des ICS zu ökonomischen Variablen durch die besondere Beachtung ab, die er dem Problem der Autokorrelation der stochastischen Größe bei der Schätzung seines Modells schenkt. Die Bewertung der Post-Sample-Prognosen leidet allerdings unter zwei von Fair nicht

- 1) Die Parameter-Schätzungen für beide Lags des ICS sind nicht signifikant, aber die hier vorgestellte Modell-Spezifikation ist nach Fair jeder anderen, die nur einen Lag aufweist, überlegen. Vgl. Fair (1971), S. 33.
- 2) Der Ausdruck "Fair-Modell" bezieht sich also nicht auf das gesamte von Fair vorgestellte ökonometrische Modell.
- 3) OBE = Office of Business Economics.
- 4) S. Fair (1971), S. 240: "... the Wharton and OBE models ... do not appear to be as accurate a forecasting tool as the model developed in this study". Zur Prognosegüte des Fair-Modells in der Post-Sample-Periode vgl. auch Fair (1974).

korrekt behandelten Aspekten. Zunächst sind die Gleichungen des OBE- und des Wharton-Modells trotz offenkundiger Autokorrelation der jeweiligen stochastischen Größe mithilfe des OLS-Verfahrens geschätzt.¹⁾ Dies sollte sich in erhöhten Fehlervarianzen der Prognosen in der Post-Sample-Periode niederschlagen. Darüberhinaus berücksichtigt Fair bei der Erstellung der Post-Sample-Prognosen seines Modells nicht die in der Sample-Periode unterstellte und geschätzte autokorrelative Struktur der stochastischen Größe.²⁾ Die Lösung dieser Probleme sollte zu einer höheren Prognosegüte aller Modelle führen; ob die ursprüngliche Reihenfolge der Modelle und damit die Schlußfolgerungen in bezug auf die Eignung des ICS zur Prognose von Gebrauchs-güterausgaben wiederholt würde, muß offen bleiben.

3. Shapiro untersucht die Abhängigkeit des ICS von ausgewählten ökonomischen Variablen für eine Sample-Periode von 1956.1 - 1970.2. Einige Ergebnisse der Schätzungen sind in Tabelle 2 ausgewiesen.

Bei der Kritik an der Untersuchung von Shapiro muß darauf hingewiesen werden, daß die mithilfe des OLS-Verfahrens geschätzten Gleichungen den jeweils um einen Lag verzögerten ICS - die abhängige Variable - unter den unabhängigen Variablen aufführen. Die DW-Statistik ist daher hier mit einem Bias gegen zwei versehen und somit ungeeignet zum Test auf Autokorrelation erster Ordnung in der stochastischen Größe.

Es muß offen bleiben, ob die von Shapiro behauptete Ersetz-

-
- 1) Dies entspricht auch dem Verfahren der Autoren, die diese Modelle entwickelten. Vgl. Green/Liebenberg/Hirsch (1972) für das OBE-Modell und Evans/Klein (1968) für das Wharton-Modell.
 - 2) Eine Berücksichtigung des Noise-Modells in der Post-Sample-Periode entfällt für das OBE- und Wharton-Modell, da die autokorrelative Struktur der stochastischen Größe schon bei der Schätzung nicht einbezogen ist.

Tabelle 2

Zusammenfassung einiger bei Shapiro (1972) ausgewiesener
Ergebnisse

(In Klammern: t-Statistik)

Sample-Periode: 1956.1 - 1970.2

$\bar{R}^2$

DW

$$\begin{aligned}
 ICS_t = & 138.64 + 29.13SP_{t-1}/SP_{t-2} \\
 & (2.15) \quad (3.89) \\
 & - 181.44PCED_{t-1}/8^{-1}\sum_{i=1}^8 PCED_{t-i} \\
 & (3.61) \\
 & + 52.77DYK_{t-1}/8^{-1}\sum_{i=1}^8 DYK_{t-i} + .59ICS_{t-1} \quad .83 \quad 2.1 \\
 & (1.71) \quad (5.83)
 \end{aligned}$$

$$\begin{aligned}
 ICS_t = & 319.36 + 29.48SP_{t-1}/SP_{t-2} \\
 & (3.18) \quad (3.89) \\
 & - 300.14PCED_{t-1}/8^{-1}\sum_{i=1}^8 PCED_{t-i} \\
 & (3.40) \\
 & - .83UM_{t-1} + .56_{t-1}ICS_{t-1} \quad .83 \quad 2.1 \\
 & (1.79) \quad (4.79)
 \end{aligned}$$

Legende:

- ICS_t ICS in quarter t;
 SP_t Standard and Poors index of industrial common
 stocks in quarter t;
 $PCED_t$ Implicit deflator for consumer expenditures in
 quarter t;
 DYK_t Disposable income net of transfers in quarter t;
 UM_t Unemployment rate (men 20 years and over) in
 percent in quarter t.

DYK_t ist für Preisveränderungen sowie saisonal adjustiert.
 $PCED_t$ und UM_t sind saisonbereinigt.

barkeit des ICS durch ökonomische Variable tatsächlich existiert oder ob sie nur auf der Fehlinterpretation der Ergebnisse von OLS-Regressionen bei autokorrelierter stochastischer Größe zurückzuführen sind.

2213 Die Kritik an der Behandlung der Autokorrelation der stochastischen Größe im Überblick

In einer groben Schematisierung, die natürlich nicht allen Aspekten der aufgeführten Untersuchungen gerecht wird, können in bezug auf die Behandlung der autokorrelativen Struktur der stochastischen Größe die folgenden Kritikpunkte festgehalten werden:

- In der Sample-Periode ist

- die DW-Statistik (oder eine andere Maßzahl der Autokorrelation der Residuen) trotz Anwendung des OLS-Verfahrens nicht ausgewiesen (Mueller (1963), Friend/Adams (1964), Suits/Sparks (1965), Juster/Wachtel (1972a) für Untersuchungen, die den ICS als unabhängige Variable behandeln; Mueller (1963), Adams/Green (1965), Suits/Sparks (1965) für Untersuchungen, die den ICS als abhängige Variable behandeln);
- Autokorrelation in der stochastischen Größe durch die DW-Statistik indiziert, aber bei der Schätzung der Modelle und der Interpretation der Ergebnisse nicht berücksichtigt (Juster (1969), Juster/Wachtel (1972b) für Untersuchungen, die den ICS als unabhängige Variable behandeln);
- die DW-Statistik ausgewiesen, aber nicht interpretierbar, weil verzögerte Werte der abhängigen Variablen unter den unabhängigen Variablen auftreten (Adams/Klein (1972) für Untersuchungen,

die den ICS als unabhängige Variable behandeln; Adams/Klein (1972), Shapiro (1972) für Untersuchungen, die den ICS als abhängige Variable behandeln).

- In der Post-Sample-Periode ist

- ein in der Sample-Periode ineffizient geschätzter Parameter-Vektor zur Erstellung der Prognosen verwendet (Juster (1969), Burch/Stekler (1969) für Untersuchungen, die den ICS als unabhängige Variable behandeln);
- das in der Sample-Periode geschätzte Noise-Modell bei der Erstellung der Prognosen nicht berücksichtigt (Burch/Stekler (1969), Hymans (1970), Fair (1971) für Untersuchungen, die den ICS als unabhängige Variable behandeln).

222 Wahl der Alternativmodelle

1. Die Untersuchungen von Juster (1969) und Burch/Stekler (1969) benutzen "naive" autoregressive Modelle, um die Güte der Post-Sample-Prognosen von Modellen, die den ICS einschließen, zu bewerten. Es muß zweifelhaft erscheinen, ob die "naiven" Modelle von Juster und Burch/Stekler die Zeitreihennatur der jeweils prognostizierten Variablen in befriedigendem Umfang erfassen.

2. Juster nimmt an, daß am Ende des Quartals t für die Prognose der Ausgaben in den Quartalen $(t + 1)$ und $(t + 2)$ als letzte bekannte Werte die der Quartale $(t - 2)$ und

(t - 1) zur Verfügung stehen. Diese durch den Zeitpunkt der Veröffentlichung der Daten auferlegten Beschränkungen sind von Juster bei der Konstruktion des autoregressiven Modells in besonderer Weise berücksichtigt: " ... we use only those lagged dependent variables that would have been available at the forecast date (the survey quarter quarter)"¹⁾.

Das von Juster verwendete Verfahren produziert im allgemeinen suboptimale Prognosen. Dies läßt sich wie folgt nachweisen.

Das Bildungsgesetz eines autoregressiven Prozesses Y_t sei gegeben durch:

$$(2.13) \quad Y_t = \sum_{j=1}^p a_j Y_{t-j} + U_t$$

wobei

$$E(U_t) = 0$$

$$E(U_t U_{t'}) = d_{tt'}, \quad \sigma_U^2$$

$$d_{tt'} = \text{Kronecker Delta}$$

Es sei angenommen, alle Wurzeln der polynomischen Gleichung

$$(1 - a_1 B - \dots - a_p B^p) = 0$$

liegen außerhalb des Einheitskreises.

Die minimale "Mean Square Error"-Prognose für Prognosedistanz 1 ist gegeben durch:²⁾

$$(2.14) \quad (Y_{t+1}) = \sum_{j=1}^p a_j (Y_{t+1-j}) + (U_{t+1})$$

1) Juster (1969), S. 225.

2) Vgl. Box/Jenkins (1976), S. 130.

Wenn mit Juster unterstellt wird, für die Prognose der Werte in den Quartalen $(t + 1)$ und $(t + 2)$ seien zum Ende des Quartals t als letzte bekannte Werte die der Quartale $(t - 2)$ und $(t - 1)$ verfügbar, müssen mithilfe der Prognoseformel (2.14) Prognosen für Prognosedistanz $l = 3$ erzeugt werden.¹⁾ Es gilt also:

$$(2.15) \quad (Y_{t+3}) = \sum_{j=1}^P a_j (Y_{t+3-j}) + (U_{t+3})$$

Für die Ausdrücke in Klammern werden die in t bekannten Werte verwendet; die in t unbekannten Werte sind mit ihren Erwartungswerten anzusetzen.

Es folgt nach einigen Umformungen:

$$(2.16) \quad (Y_{t+3}) = \sum_{j=0}^P c_j Y_{t-j} + \sum_{j=0}^P a_{3+j} Y_{t-j}$$

wobei

$$c_j = (a_1^2 + a_2) a_{1+j} + a_1 a_{2+j}$$

Dagegen setzt Juster, um der Verfügbarkeit der Daten Rechnung zu tragen, die Parameter a_1 und a_2 mit null an.²⁾ Die von Juster verwendete Prognose $(Y_{t+3})_J$ von Y_{t+3} lautet demnach:

$$(2.17) \quad (Y_{t+3})_J = \sum_{j=0}^P a_{3+j} Y_{t-j}$$

-
- 1) Die Prognosedistanz $l = 1$ bezieht sich auf die Quartale $(t - 1)$ und t ; die Prognosedistanz $l = 2$ bezieht sich auf die Quartale t und $(t + 1)$.
 - 2) " ... the first lag term available for the pure forecast model is actually the third lag term in the series." Juster (1969), S. 226.

Die optimale Prognose von Y_{t+3} (vgl. Gleichung (2.16)) unterscheidet sich von der mit Justers Verfahren erzielten um die Größe

$$(2.18) \quad \sum_{j=0}^p c_j Y_{t-j}$$

Im allgemeinen wird die Vernachlässigung dieses Ausdrucks zu einer suboptimalen Prognose führen.

3. Burch/Stekler verwenden zwei "naive" Modelle. Das erste "naive" Modell nimmt einen Random Walk-Prozeß an:

$$(2.19) \quad (1 - B)CDM_{t+1,t+2} = U_t$$

Das zweite "naive" Modell unterstellt:

$$(2.20) \quad (1 - B)(CDM_{t+1,t+2} - CDM_t) = U_t$$

$CDM_{t+1,t+2}$ bzw. CDM_t sind wie in Gleichung (2.11) definiert, U_t ist weißes Rauschen und B der Lag-Operator.

Die Suboptimalität beider Modelle ergibt sich aus der Betrachtung des Autokorrelogramms der ersten Differenzen von $CDM_{t+1,t+2}$, wie im Vorgriff auf spätere Untersuchungsergebnisse aus Tabelle 7 zu entnehmen ist. Es lassen sich Modelle spezifizieren, die die Zeitreihennatur von $CDM_{t+1,t+2}$ besser erfassen.¹⁾

1) Die der Berechnung des Autokorrelogramms zugrundeliegende Sample-Periode weicht von der bei Burch/Stekler ab. Da die ersten Differenzen von $CDM_{t+1,t+2}$ jedoch als Realisation eines stationären stochastischen Prozesses anzusehen sind, sollte diese Unterscheidung ohne Belang sein.

223 Methode der Modell-Spezifikation

Durchgehend ist in den vorliegenden Untersuchungen die Frage der Modell-Spezifikation - insbesondere die Lag-Verteilung der unabhängigen Variablen und der stochastischen Größe - in der Weise zu beantworten gesucht, daß unterschiedliche Spezifikationen in einem "trial and error"-Verfahren nach dem Kriterium der besten Erklärungskraft des Modells und/oder der Signifikanz der Parameter-Schätzungen geprüft werden. Da - wie zu Beginn von Abschnitt 2 ausgeführt - die Theorie der "Psychological Economics" keine direkten Hinweise auf die Spezifikation von Modellen gibt, die die Beziehungen des ICS zu ökonomischen Variablen beschreiben, ist die Dominanz dieser "trial and error"-Verfahren zumindestens erklärbar.

Diese Verfahren können allerdings nicht befriedigen, da schon für Modelle mit nur einer unabhängigen Variablen eine Vielzahl von Spezifikationsmöglichkeiten existiert, die auf unterschiedlichen Formen der Lag-Verteilung dieser unabhängigen Variablen und der stochastischen Größe beruhen. Es ist im allgemeinen eine nicht zu bewältigende Aufgabe, die Relevanz aller alternativen Spezifikationen bewerten zu wollen.

3 Entwurf eines eigenen Analyse-Designs

1. Die bisherigen Ausführungen haben die Notwendigkeit belegt, die Beziehung des ICS zu ökonomischen Variablen erneut zu analysieren. Es kann aufgrund der Mängel der vorgestellten Untersuchungen jedenfalls nicht davon gesprochen werden, der von der Theorie der "Psychological Economics" behauptete Zusammenhang zwischen dem Konsumklima, repräsentiert durch den ICS, und ökonomischen Variablen sei empirisch ausreichend überprüft.

In Entsprechung zu den in Abschnitt 22 genannten Kritikpunkten konzentriert sich die folgende empirische Analyse auf zwei Teile.

2. Im ersten Teil der empirischen Analyse wird in einer Post-Sample-Bewertung festgestellt, ob ein den ICS einschließendes Modell, das unter Berücksichtigung der autokorrelativen Struktur der stochastischen Größe geschätzt ist und dessen Post-Sample-Prognosen auch auf die in der Sample-Periode ermittelte autokorrelative Struktur der stochastischen Größe zurückgreifen, eine bessere Prognosegüte aufweist als ein möglichst optimal konstruiertes "naives" Modell, dessen Prognosen ausschließlich auf den Werten der zu prognostizierenden Variablen selbst basieren.

Bei der Wahl des den ICS einschließenden Modells wird auf in früheren Untersuchungen bereits verwendete Spezifikationen zurückgegriffen. Die Spezifikation des "naiven" Modells beruht auf der von Box/Jenkins empfohlenen Strategie.¹⁾

Mit diesem ersten Teil der empirischen Analyse werden mehrere Ziele verfolgt.

1) Vgl. Box/Jenkins (1976).

Bei der Schätzung des Modells kann geprüft werden, ob die in der ursprünglichen Untersuchung abgegebenen Urteile im Lichte adäquater Schätzverfahren aufrechtzuerhalten sind. Diese Prüfung ist natürlich nur dort sinnvoll, wo das verwendete Schätzverfahren von dem in der ursprünglichen Untersuchung abweicht.

Mit der Verlegung der Prognose-Bewertung in die Post-Sample-Periode kann die Aussagefähigkeit eines Modells außerhalb der Periode, in der es geschätzt wird, getestet werden.¹⁾ Dieser Ansatz trägt darüberhinaus der tatsächlichen Situation eines Prognoseerstellers Rechnung, der die zu prognostizierenden Werte einer Serie in aller Regel nicht auch zur Schätzung eines Modells verwenden kann.²⁾

Die Einbeziehung des Noise-Modells bei der Erstellung der Post-Sample-Prognosen - in keiner der bisherigen Untersuchungen vorgenommen - soll bei einer Neueinschätzung der Prognosegüte von Modellen, die den ICS einschließen, hilfreich sein.

Schließlich beantwortet die Bewertung mithilfe eines "naiven" Modells die Frage, ob die gleiche oder eine ähnliche Prognosegüte auch kostengünstiger erreicht werden kann. "Extrapolation of past values are relatively simple and inexpensive forecasting procedures which can be defined

1) Zur Befürwortung einer Post-Sample-Evaluierung s. z.B. Dhrymes et al. (1972), S. 17: "... in a realistic situation in which model selection procedures, hypothesis tests of various kinds, and a number of other "experiments" all amount to considerable data-mining, it would seem wise to have saved some data on which to evaluate the resulting model"; Granger/Newbold (1977), S. 290: "... given sufficient effort, one can almost always obtain a reasonably good fit to a set of sample data. The worth of such a fit however ought to be verified outside the sample period before placing any great confidence in a model"; Friend/Jones (1964), S. 322: "It is relatively easy to get good fits and much more difficult to get good forecasts". Vgl. auch Christ (1975), S. 54 ff., insbes. S. 72 f.; Shapiro (1972), S. 379.

2) Vgl. Shapiro (1972), S. 379.

and reproduced. A forecast may be judged satisfactory according to its absolute errors; but if a less costly extrapolation is about as accurate, the comparative advantage is on the side of the extrapolation".¹⁾

3. Im zweiten Teil der empirischen Analyse wird ein eigen-
Beitrag zur Diskussion über die Spezifikation der Bezie-
hungen zwischen dem ICS und ökonomischen Variablen ent-
wickelt.

Den Vorschlägen von Box/Jenkins²⁾ und Granger/Newbold³⁾
folgend wird eine rein datengesteuerte Spezifikation, die
keinen Gebrauch von Konzepten der ökonomischen Theorie
macht, vorgenommen.

1) Mincer/Zarnowitz (1969), S. 44. Vgl. auch in diesem
Sinne Spencer/Clark (1965), S. 21, Klein (1968), S. 42
ff., Juster (1969), S. 225, Theil (1970), S. 65 f.,
Fair (1971), S. 299, Evans et al. (1972), S. 967,
Cooper (1972), S. 814 ff.

2) Vgl. Box/Jenkins (1976).

3) Vgl. Granger/Newbold (1977).

4 Erster Teil der empirischen Analyse: Bewertung der Prognosegüte des ICS in einer Post-Sample-Periode

4.1 Vorstellung der den ICS einschließenden Modelle

Der erste Teil der empirischen Analyse befaßt sich mit der Bewertung der Prognosegüte des ICS in bezug auf diskretionäre Konsumausgaben in einer Post-Sample-Periode, wobei in der Literatur bereits verwendete Modelle herangezogen werden.

Da die Theorie der "Psychological Economics" sich nicht auf eine bestimmte Spezifikation eindeutig festlegt, stehen im Prinzip alle bisherigen Ansätze als gleichwertige Alternativen zur Verfügung. Es ist zweifellos sinnvoll, sich im Interesse der Übersichtlichkeit auf eine beschränkte Zahl möglichst unterschiedlich spezifizierter Modelle zu beschränken.

Zur Erstellung der Post-Sample-Prognosen sind daher das Mueller-Modell und das Fair-Modell verwendet.

Das Mueller-Modell ist als lineares Regressionsmodell mit nur zwei unabhängigen Variablen spezifiziert. Neben seiner einfachen Spezifikation ist ein weiterer Grund für die Wahl die Bedeutung, die ihm in anderen Untersuchungen beigemessen wird.¹⁾

Das Fair-Modell ist die Strukturgleichung eines ökonometrischen Modells und steht somit im Vergleich zum Mueller-Modell auf einer anspruchsvolleren ökonometrischen Basis. Seine Besonderheit liegt weniger in seiner Spezifikation - die der des Mueller-Modells sogar recht ähnlich ist - als

1) Vgl. S. 15 ff.

in dem von Fair verwendeten Verfahren zur Schätzung der strukturellen Parameter, das die Einbeziehung der Strukturgleichung in das gesamte System des zugrundeliegenden ökonomischen Modells berücksichtigt.

Im folgenden sind die für die Prognosebewertung wesentlichen Aspekte des Mueller- und des Fair-Modells - insbesondere Einzelheiten der Schätzverfahren - dargestellt.

411 Mueller-Modell

1. Das Mueller-Modell ist wie folgt spezifiziert:

$$(4.1) \quad \text{CDM}_{t+1,t+2} = c_0 + c_1 \text{YDM}_{t-2,t-1} + c_2 \text{ICS}_t + U_{t+1,t+2}$$

Zur Bedeutung der Variablen vgl. Gleichung (2.11).

2. Zur autokorrelativen Struktur der stochastischen Größe finden sich bei Mueller (1963) keine Angaben. Aufgrund der Definition als gleitender Halbjahreswert sollte $U_{t+1,t+2}$ jedoch autokorreliert sein. Selbst wenn U_t - der reine Quartalswert - nämlich weißes Rauschen wäre, so folgte $U_{t+1,t+2}$ einem (nicht invertiblen) Moving Average-Prozeß erster Ordnung, dessen Autokorrelationen ungleich null sind für Lag $k = 1$.

In Abschnitt 22 sind die Probleme für die Interpretation von $\bar{R}^2$, der t- und F-Statistik aufgezeigt, die auftreten, wenn OLS-Regressionen bei Existenz von Autokorrelation in der stochastischen Größe durchgeführt werden. Die Notwendigkeit, diesen Problemen bei der Schätzung des Mueller-Modells besondere Aufmerksamkeit zu schenken, ist bereits oben begründet. Das im folgenden zur Schätzung des Mueller-Modells verwendete Verfahren berücksichtigt daher

die Möglichkeit einer autokorrelierten stochastischen Größe. Das von Durbin empfohlene Verfahren¹⁾ - im weiteren als "Durbin-Verfahren" bezeichnet - kann auch autokorrelativen Strukturen der stochastischen Größe, die von der des autoregressiven Prozesses erster Ordnung abweicht, Rechnung tragen.

3. Die Elemente des Durbin-Verfahrens lassen sich wie folgt beschreiben. Das zu schätzende lineare Regressionsmodell sei von der Form:

$$(4.2) \quad Y_t = b_1 X_{1,t} + \dots + b_k X_{k,t} + U_t \\ t = 1, \dots, T$$

Y_t ist also die abhängige Variable, die $X_{i,t}$ ($i = 1, \dots, k$) sind die unabhängigen Variablen, und U_t ist die stochastische Größe. Die b_i ($i = 1, \dots, k$) sind die zu schätzenden Parameter. Wenn $X_{1,t}$ als Dummy-Variable angesehen wird, die für alle t den Wert 1 annimmt, ist b_1 die Konstante der Gleichung.

Es sei unterstellt, die stochastische Größe gehorche einem autoregressiven Prozeß zweiter Ordnung:

$$(4.3) \quad (1 - a_1 B - a_2 B^2) U_t = E_t$$

B ist der Lag-Operator, a_1 und a_2 sind die autoregressiven Parameter, und E_t ist weißes Rauschen, d.h.

$$(4.4) \quad E(E_t E_{t'}) = d_{tt}, \sigma_E^2$$

wobei d_{tt} , das Kronecker Delta und σ_E^2 die für alle t konstante Varianz von E_t ist. Es sei ferner angenommen, daß

1) Vgl. Durbin (1960). Das Durbin-Verfahren hat gute Resultate in einer Monte Carlo-Studie von Griliches/Rao (1969) erbracht.

$$E(E_t) = 0$$

Aus (4.2) und (4.3) wird eine kombinierte Gleichung gebildet:

$$(4.5) \quad Y_t = a_1 Y_{t-1} + a_2 Y_{t-2} + b_1 X_{1,t} + \dots + b_k X_{k,t} \\ - a_1 b_1 X_{1,t-1} - \dots - a_1 b_k X_{k,t-1} \\ - a_2 b_1 X_{1,t-2} - \dots - a_2 b_k X_{k,t-2} + E_t$$

Eine OLS-Regression von (4.5) liefert Schätzungen $\hat{a}_1$ und $\hat{a}_2$ der autoregressiven Parameter a_1 und a_2 ; mithilfe dieser Schätzungen werden die Variablen in (4.2) transformiert:

$$(4.6) \quad Y_t^{tr} = Y_t - \hat{a}_1 Y_{t-1} - \hat{a}_2 Y_{t-2} \\ X_{i,t}^{tr} = X_{i,t} - \hat{a}_1 X_{i,t-1} - \hat{a}_2 X_{i,t-2} \\ i = 1, \dots, k$$

Eine OLS-Regression von (4.2), wobei jeweils die in (4.6) transformierten Variablen Y_t^{tr} bzw. $X_{i,t}^{tr}$ verwendet werden, erbringt asymptotisch effizientere Schätzungen als die OLS-Regression von (4.2), wenn die ursprünglichen Variablen Y_t bzw. $X_{i,t}$ zugrundeliegen.

4. Mithilfe des Mueller-Modells sind Prognosen nur von $CDM_{t+1,t+2}$ bzw. $CAM_{t-1,t+2}$ erstellt, d.h. nur für eine einzige Prognosedistanz. Die Erstellung von Prognosen für verschiedene Prognosedistanzen setzt die Kenntnis des Erzeugungsmechanismus¹⁾ der unabhängigen Variablen voraus; diese Information wird im Rahmen des Mueller-Modells nicht geliefert.

1) Unter gewissen Voraussetzungen in bezug auf die autokorrelative Struktur des Noise-Modells können allerdings Prognosen der stochastischen Größe für beliebige Prognosedistanzen erstellt werden.

5. Die Post-Sample-Prognosen des Mueller-Modells sind sowohl mit wie auch ohne das Noise-Modell erstellt. Zwar interessieren für den Vergleich mit den Prognosen bzw. Prognosefehlern des "naiven" Modells in erster Linie die Prognosen, die das Noise-Modell berücksichtigen. Die Güte der ohne das Noise-Modell erstellten Prognosen erlaubt jedoch wertvolle Rückschlüsse auf die Bedeutung des Noise-Modells für das Mueller-Modell.

6. Die in der Sample- und Post-Sample-Periode verwendeten Werte aller Variablen sind Daten-Bändern des Survey Research Center entnommen.

412 Fair-Modell

1. Das Fair-Modell ist wie folgt spezifiziert:¹⁾

$$(4.7) \quad CDF_t = c_0 + c_1 \overline{GNP}_t + c_2 ICS_{t-1} + c_3 ICS_{t-2} + U_t$$

Zur Bedeutung der Variablen vgl. Gleichung (2.12). Der Strich über GNP_t verweist wieder auf das verwendete Schätzverfahren.

In Fairs ökonometrischem Modell findet sich keine Strukturgleichung für Autoausgaben. Um die Parallele zum Mueller-Modell herzustellen und um der vorliegenden Unter-

1) Die Notation weicht hier und im folgenden geringfügig von der bei Fair (1971) ab. Dies ist im Interesse der Unterscheidbarkeit notwendig.

suchung eine breitere Basis zu verschaffen, sind Autoausgaben als zusätzliche endogene Variable eingeführt. Zu diesem Zweck wird CAF_t definiert, wobei

CAF_t Consumer expenditures on motor vehicles
 and parts in quarter t .

Auch CAF_t ist saison-, nicht jedoch preisbereinigt.

Es ist für CAF_t die gleiche Strukturgleichung wie für CDF_t verwendet, d.h. mit $\overline{GNP}_t$, ICS_{t-1} und ICS_{t-2} als unabhängigen Variablen. Die Einbeziehung einer zusätzlichen endogenen Variablen verändert das angewandte Schätzverfahren geringfügig; Art und Umfang dieser Veränderung sind unten beschrieben.

2. Das von Fair empfohlene Schätzverfahren macht Gebrauch von einer Anzahl anderer Variablen des gesamten ökonometrischen Modells, wodurch die Beziehung zu einem weiteren kausalen Zusammenhang sichtbar wird. Zum besseren Verständnis dieses Verfahrens sei im folgenden eine kurze Beschreibung des von Fair entwickelten ökonometrischen Modells gegeben.

Als Besonderheiten des ökonometrischen Modells von Fair müssen genannt werden:

- die im Vergleich zu anderen ökonometrischen Modellen geringe Anzahl der Strukturgleichungen;
- die hervorgehobene Bedeutung von als exogen definierten psychologischen Variablen.

Das ökonometrische Modell von Fair beschreibt die Beziehungen

zwischen 19 endogenen und 16 exogenen Variablen. Es ist in vier Sektoren gegliedert, die von Fair jeweils als abgeschlossene Einheit behandelt werden:¹⁾

- GNP sector;
- Housing starts sector;
- Price sector;
- Employment and labor force sector.

Es werden neben CDF_t sechs Ausgabekategorien des "GNP sector" als endogene Variable definiert:²⁾

CNF_t	Personal consumption expenditures for nondurable goods in quarter t;
CSF_t	Personal consumption expenditures for services in quarter t;
IP_t	Nonresidential fixed investment in quarter t;
V_t	Change in total business inventories in quarter t;
IH_t	Nonfarm residential investment in quarter t;
IMP_t	Imports of goods and services in quarter t.

Die exogenen Variablen des "GNP sector" sind:

FEX_t	Sum of government expenditures plus farm residential fixed investment plus exports in quarter t;
ICS_t	ICS in quarter t;

1) Vgl. Fair (1971), S. 11 ff.

2) Vgl. ibid., S. 11 f. und S. 25.

PE1 _t	One-quarter-ahead expectations of plant and equipment investment in quarter t;
PE2 _t	Two-quarter-ahead expectations of plant and equipment investment in quarter t;
HSQ _t	Quarterly nonfarm housing starts.

Alle Geld-Variablen sind wieder saisonal, nicht jedoch für Preisveränderungen adjustiert. HSQ_t ist saisonal adjustiert.

Da GNP_t sich definitionsgemäß aus den genannten sieben endogenen Variablen und FEX_t zusammensetzt, ist GNP_t selbst eine endogene Variable.

3. Fair verwendet zur Schätzung einer Strukturgleichung des "GNP sector" seines ökonometrischen Modells ein Verfahren, das der Simultaneität der endogenen Variablen sowie einer autoregressiven Beziehung erster Ordnung in der stochastischen Größe Rechnung trägt. Dieses Verfahren stellt im wesentlichen eine Kombination der 2SLS- und der Cochrane/Orcutt-Methode dar. Die Grundzüge des Verfahrens ähneln einer von Sargan vorgeschlagenen Methode.¹⁾ Die folgende Darstellung ist notwendigerweise kurz und beschränkt sich auf die Beschreibung der Voraussetzungen und der Elemente des Verfahrens. Der Beweis für die Konsistenz des Verfahrens wird nicht geliefert.²⁾

Fair geht von einer Strukturgleichung der folgenden Form aus:

$$(4.8) \quad \underline{y}_1 = - \underline{Y}_1 \underline{A}_1 - \underline{X}_1 \underline{B}_1 + \underline{U}_1$$

$\underline{y}_1$ ist der (T x 1)-Vektor der T Beobachtungen der endogenen

1) Vgl. Sargan (1961). Fair benützt eine geringere Zahl von Instrument-Variablen.

2) Vgl. hierzu Fair (1974).

Variablen y_1 . $\underline{Y}_1$ ist die $(T \times m)$ -Matrix der T Beobachtungen der m anderen in der Strukturgleichung für y_1 enthaltenen endogenen Variablen, $\underline{X}_1$ ist die $(T \times k)$ -Matrix der T Beobachtungen der k in der Strukturgleichung für y_1 enthaltenen exogenen Variablen, $\underline{U}_1$ ist der $(T \times 1)$ -Vektor der T Beobachtungen der stochastischen Größe, und $\underline{A}_1$ bzw. $\underline{B}_1$ sind die $(m \times 1)$ - bzw. $(k \times 1)$ -Vektoren der zu schätzenden Parameter.

Die stochastische Größe folge einem autoregressiven Prozeß erster Ordnung:

$$(4.9) \quad (1 - a_{11}B)\underline{U}_{1,t} = \underline{E}_{1,t} \\ t = 1, \dots, T$$

B ist der Lag-Operator, a_{11} ist der autoregressive Parameter und $\underline{E}_{1,t}$ ist weißes Rauschen, d.h.

$$(4.10) \quad E(\underline{E}_{1,t}\underline{E}_{1,t'}) = d_{tt'} \sigma_{\underline{E}_1}^2$$

wobei $d_{tt'}$ das Kronecker Delta und $\sigma_{\underline{E}_1}^2$ die für alle t konstante Varianz von $\underline{E}_{1,t}$ ist. Es sei ferner angenommen, daß

$$E(\underline{E}_{1,t}) = 0$$

Aus (4.8) und (4.9) ergibt sich:

$$(4.11) \quad \underline{y}_1 - a_{11}\underline{y}_{1-1} = -(\underline{Y}_1 - a_{11}\underline{Y}_{1-1})\underline{A}_1 \\ - (\underline{X}_1 - a_{11}\underline{X}_{1-1})\underline{B}_1 + \underline{E}_1$$

In $\underline{y}_{1-1}$, $\underline{Y}_{1-1}$ bzw. $\underline{X}_{1-1}$ sind alle Elemente gegenüber denen

in y_1 , $\underline{Y}_1$ bzw. $\underline{X}_1$ um einen Lag verzögert. $\underline{E}_1$ ist der $(T \times 1)$ -Vektor von T Beobachtungen der stochastischen Größe.

In (4.11) ist $\underline{E}_1$ korreliert mit $\underline{Y}_1$; das OLS-Verfahren liefert daher inkonsistente Schätzungen der Parameter-Vektoren $\underline{A}_1$ und $\underline{B}_1$. Nach Fair kann (4.11) jedoch konsistent mithilfe eines dreistufigen Verfahrens geschätzt werden:

- Es werden Instrument-Variable gewählt, die unkorreliert mit $\underline{E}_1$ sind und zumindestens y_{1-1} , $\underline{Y}_{1-1}$, $\underline{X}_1$ und $\underline{X}_{1-1}$ enthalten. Für jede endogene Variable in $\underline{Y}_1$ wird eine OLS-Regression auf diese Instrument-Variablen durchgeführt. Die hieraus resultierende Schätzung von $\underline{Y}_1$ wird mit $\hat{\underline{Y}}_1$ bezeichnet.
- Gleichung (4.11) wird mithilfe des OLS-Verfahrens geschätzt, wobei $\underline{Y}_1$ durch $\hat{\underline{Y}}_1$ ersetzt wird. ($\underline{Y}_{1-1}$ verbleibt in der Gleichung)
- Die in der zweiten Stufe geschätzten Parameter-Vektoren werden in (4.8) eingesetzt und eine Anfangsschätzung von a_{11} errechnet. Mithilfe der Cochrane/Orcutt-Technik werden iterativ diejenigen Schätzungen von $\underline{A}_1$, $\underline{B}_1$ und a_{11} gesucht, für die die Summe der quadrierten Residuen der zweiten Stufe ein Minimum wird.

Fair verwendet bei der Schätzung der Strukturgleichung von CDF_t zusätzlich zu den oben als notwendig bezeichneten Instrument-Variablen einige verzögerte endogene Variable sowie weitere exogene Variable. Die Auswahlkriterien für

die zusätzlichen Variablen sind von Fair nicht eindeutig genannt.¹⁾ In der vorliegenden Untersuchung werden die von Fair gewählten Variablen weitgehend übernommen. Notwendige Abweichungen sind unten genannt. Es ist jedoch darauf geachtet, daß die Instrument-Variablen stets zumindestens die in der ersten Stufe aufgeführten Variablen umfassen.

4. Einige Unterschiede des hier verwendeten zu dem von Fair empfohlenen Verfahren sind hervorzuheben. CAF_{t-1} und CAF_{t-2} sind unter den zur Substitution von GNP_t benutzten Variablen, da hier CAF_t eine endogene Variable ist.²⁾ Fair führt als weitere Variable bei den Instrument-Variablen $PE2_t$ auf. Diese Variable wird erst ab dem dritten Quartal von 1961 im "Survey of Current Business" veröffentlicht. Es erscheint nicht zweckmäßig, die Sample-Periode erst in 1961.3 beginnen zu lassen; $PE2_t$ ist daher hier nicht berücksichtigt.

GNP_t ist demnach gebildet aufgrund der Regression von GNP_t auf die Instrument-Variablen ($1, GNP_{t-1}, CDF_{t-1}, CDF_{t-2}, CAF_{t-1}, CAF_{t-2}, CNF_{t-1}, CNF_{t-2}, CSF_{t-1}, CSF_{t-2}, V_{t-1}$

-
- 1) Fair begründet die Wahl zusätzlicher verzögerter endogener Variablen mit den Anforderungen an die Konsistenz seines Verfahrens: "... those lagged endogenous variables that were not among the predetermined variables ... were not used as instruments except in those equations in which it was necessary to do so to insure consistent estimates", Fair (1971), S. 22. Tatsächlich verwendet Fair jedoch auch verzögerte endogene Variable, die für die Konsistenz des Verfahrens nicht notwendig sind. Offensichtlich stellt dies eine Ausweitung von Fairs Verfahren in Richtung auf das von Sargan empfohlene dar.
 - 2) Von den verzögerten endogenen Variablen zählen nur CDF_{t-1} (in der Strukturgleichung für CDF_t), CAF_{t-1} (in der Strukturgleichung für CAF_t) und GNP_{t-1} zu den notwendigen Instrument-Variablen. Fair addiert jedoch in der Strukturgleichung für CDF_t ein- und zweifach verzögerte Werte von CNF_t und CSF_t sowie CDF_{t-2} zu den Instrument-Variablen. Dem gleichen Verfahren ist hier gefolgt. Dies erklärt die Existenz von CAF_{t-1} und CAF_{t-2} unter den Instrument-Variablen.

$FEX_t, ICS_{t-1}, ICS_{t-2}, ICS_{t-3})$.¹⁾

5. Ein weiterer Unterschied zu Fair betrifft die Behandlung von Quartalen, in denen größere Streiks stattfanden. Fair hat die Beobachtungswerte der Quartale 1959.3, 1959.4 und 1960.1 wegen eines Streiks in der Stahlindustrie und die der Quartale 1964.4, 1965.1 und 1965.2 wegen eines Streiks in der Automobilindustrie aus der Sample-Periode entfernt, um die besonderen Effekte dieser Faktoren auf GNP_t und seine Komponenten auszuschalten. Fair selbst bezeichnet dieses Verfahren als ungewöhnlich: "The procedure of excluding particular quarters from the sample period because of strikes is a little unusual"²⁾. Tatsächlich ist nicht einzusehen, warum die möglicherweise wertvolle Information, die in den ausgeschlossenen Quartalen liegt, völlig negiert werden sollte. Der Einfluß des ICS auf diskretionäre Konsumausgaben könnte durchaus auch in diesen Quartalen wirksam sein. Es erscheint sinnvoller, die Einflüsse schwer prognostizierbarer Faktoren wie Streiks, Wetter, etc., unter der stochastischen Größe zu subsummieren, die im Rahmen eines ökonometrischen Modells unerklärt bleibt. Da auch in Zukunft mit dem Auftreten solcher Faktoren gerechnet werden muß, würde die Erklärungskraft eines Modells überschätzt, wenn die Schätzung nur auf "normalen" Beobachtungswerten beruhte. Das Fair-Modell ist daher ohne Auslassung von Beobachtungswerten geschätzt.

1) FEX_t tritt auch bei Fair nur in unverzügter Form auf. FEX_t ist eine exogene Variable, die allerdings nicht in der Strukturgleichung für CDF_t enthalten ist und daher nicht zum notwendigen Set der Instrument-Variablen zählt. Fair verwendet FEX_t dennoch als Instrument-Variable, da die Zahl der Instrument-Variablen hier nicht groß ist. Nach Sargan sollte auch FEX_{t-1} zu den Instrument-Variablen gehören; dies ist nach Fair hier überflüssig, da FEX_t Bestandteil von GNP_t ist und GNP_{t-1} nicht in der Strukturgleichung für CDF_t auftritt.^{t-1} Vgl. Fair (1971), S. 22.

2) Fair (1971), S. 27.

6. Mithilfe des Fair-Modells sind Prognosen jeweils von CDF_t bzw. CAF_t erstellt; Prognosen für längere Prognosedistanzen sind - wie beim Mueller-Modell - nicht möglich, da der Erzeugungsmechanismus der unabhängigen Variablen - GNP_t bzw. der Instrument-Variablen sowie von ICS_{t-1} und ICS_{t-2} - von Fair als unbekannt angesehen ist.¹⁾

Ein besonderes Problem tritt bei der Behandlung von FEX_t auf. FEX_t zählt zu den Instrument-Variablen für GNP_t , und die Identität des Zeit-Index' von CDF_t bzw. CAF_t und FEX_t erfordert die Kenntnis von FEX_t zu einem Zeitpunkt ($t - 1$), zu dem er noch nicht bekannt sein kann. Da die durch die Politik inspirierten Veränderungen der Staatsausgaben innerhalb seines ökonometrischen Modells nicht erklärt werden, schlägt Fair die Verwendung der tatsächlichen Werte von FEX_t vor.²⁾ Dieses Verfahren kann nicht überzeugen. Für die Beurteilung der Prognosen in einer Post-Sample-Periode ist der Nachvollzug der realen Situation eines Prognoseerstellers entscheidend. Zum Zeitpunkt der Erstellung einer Prognose sind jedoch regelmäßig die zukünftigen Werte der unabhängigen Variablen unbekannt; ihre Verwendung würde ein zu optimistisches Bild von der Prognosegüte in der Post-Sample-Periode zeichnen.

Fairs Verfahren wird daher nicht gefolgt. Um die Situation bei der Erstellung von Post-Sample-Prognosen wirklichkeitsgetreu nachzuzeichnen, wird FEX_t selbst prognostiziert. Da die Bestimmungsfaktoren von FEX_t jedoch - wie bei Fair - als unbekannt gelten müssen, basiert die Prognose ausschließlich auf den Informationen, die die autokorrelative Struktur von FEX_t selbst liefert. Zur Spezifikation eines univariaten

1) Wiederum können allerdings unter gewissen Voraussetzungen Prognosen der stochastischen Größe des Fair-Modells für beliebige Prognosedistanzen erstellt werden.

2) S. Fair (1971), S. 202 f.: "It is beyond the scope of the study to attempt to forecast the policy decisions of government officials, and thus the actual values of federal government spending ... have been used".

Modells für FEX_t wird das gleiche Verfahren wie zur Spezifikation der "naiven" Modelle verwendet. Einzelheiten des Verfahrens sind in Abschnitt 42 erläutert.

7. Die Post-Sample-Prognosen des Fair-Modells werden wie die des Mueller-Modells mit und ohne das Noise-Modell erstellt, um eine Vorstellung von der Bedeutung des Noise-Modells zu erhalten.

8. Die in der Sample- und Post-Sample-Periode verwendeten Werte aller Variablen mit Ausnahme des ICS sind für die Periode 1954.1 - 1973.4 entnommen aus United States Department of Commerce/Bureau of Economic Analysis (1977).¹⁾ Für 1974.1 - 1976.3 entstammen die Werte dem "Survey of Current Business".²⁾

Der ICS ist wie bei der Bewertung des Mueller-Modells den Daten-Bändern des Survey Research Centers entnommen.³⁾

Fair benutzt Quartalsdaten auf jährlicher Basis.⁴⁾ Für die Erstellung von Prognosen ist es zweckmäßiger, mit reinen Quartalsdaten zu arbeiten, um eine anschauliche Vorstellung von der Größenordnung der Prognosefehler zu erhalten. Alle in Geldeinheiten ausgedrückten Variablen sind deshalb auf reine Quartalsdaten umgerechnet.

42 Die "naiven" Modelle: univariate ARIMA- bzw. ARMA-Modelle

- 1) Mit Ausnahme von CAF_t sind die Werte in Table 1.1. ausgewiesen. CAF_t ist Table 2.3. entnommen.
- 2) Auf Seite S1 der Ausgabe von April 1977.
- 3) Die zur Prognose-Bewertung des Mueller-Modells verwendeten, den Daten-Bändern des Survey Research Center entstammenden Werte für Gebrauchsgüter- und Autoausgaben sind hier ungeeignet, da Fair nicht für Preisveränderungen adjustierte Werte benutzt, die Daten des Survey Research Center jedoch in realen Größen ausgedrückt sind.
- 4) Die offizielle Bezeichnung lautet: "Quarterly totals at annual rates". Die Quartalsdaten sind dabei jeweils mit 4 multipliziert.

421 Allgemeines

1. Als "naive" Alternative zum Mueller- und Fair-Modell sind jeweils Modelle aus der Klasse der univariaten ARIMA-Prozesse der Ordnung (p,d,q) ("Autoregressive integrated moving average processes of order (p,d,q) ") gewählt, deren parametrische Repräsentation lautet:¹⁾

$$(4.12) \quad (1 - a_1 B - \dots - a_p B^p)(1 - B)^d X_t = (1 - b_1 B - \dots - b_q B^q) U_t$$

bzw.

$$a(B)(1 - B)^d X_t = b(B) U_t$$

wobei

X_t	Homogen nichtstationärer stochastischer Prozeß;
d	Zahl sukzessiver Differenzen, die notwendig sind, den homogen nichtstationären Prozeß X_t in einen stationären Prozeß zu transformieren;
p	Ordnung des autoregressiven Teils des ARIMA-Prozesses;
q	Ordnung des Moving Average Teils des ARIMA-Prozesses;
U_t	Stochastische Größe;
B	Lag-Operator;
$t = 1, 2, \dots$	

Die stochastische Größe U_t ist weißes Rauschen, d.h.

$$(4.13) \quad E(U_t U_{t'}) = d_{tt}, \sigma_U^2$$

1) Vgl. Box/Jenkins (1976), S. 92, Granger/Newbold (1977), S. 71.

wobei d_{tt} , das Kronecker Delta und σ_U^2 die für alle t konstante Varianz von U_t ist. Es sei ferner angenommen, daß

$$E(U_t) = 0$$

Der Prozeß Z_t wird als univariater ARMA-Prozeß der Ordnung (p, q) bezeichnet, wobei

$$(4.14) \quad Z_t = (1 - B)^d X_t$$

Stationarität¹⁾ von Z_t ist unter den getroffenen Voraussetzungen gegeben, wenn alle Wurzeln der polynomischen Gleichung

$$(4.15) \quad (1 - a_1 B - \dots - a_p B^p) = 0$$

außerhalb des Einheitskreises liegen.²⁾

Zusätzlich sei angenommen, Z_t sei invertibel, d.h. alle Wurzeln der polynomischen Gleichung

$$(4.16) \quad (1 - b_1 B - \dots - b_q B^q) = 0$$

- 1) Hier und im folgenden wird der Begriff der Stationarität stets im Sinne von "schwach stationär" verstanden, d.h. die ersten beiden Momente der Wahrscheinlichkeitsverteilung von Z_t seien zeitinvariant. Zur Definition von schwacher Stationarität vgl. Jenkins/Watts (1968), S. 179, Hannan (1970), S. 201 ff., Dhrymes (1974), S. 385, Kashyap (1976), S. 13, Granger/Newbold (1977), S. 4.
- 2) Vgl. Box/Jenkins (1976), S. 53, Jenkins/Watts (1968), S. 169. Bezogen auf den homogen nichtstationären Prozeß X_t bedeutet dies, daß die Wurzeln der polynomischen Gleichung


$$a(B)(1 - B)^d = 0$$

auf dem Einheitskreis, alle anderen Wurzeln außerhalb des Einheitskreises liegen müssen. Vgl. Box/Jenkins (1976), S. 92.

lügen außerhalb des Einheitskreises.¹⁾

Eine Veranschaulichung des Sinngehaltes eines ARIMA-Prozesses ergibt sich aus Zeichnung 1.²⁾ X_t ist also erzeugt durch weißes Rauschen, das nacheinander durch einen invertiblen Moving Average Filter $b(B)$, einen stationären autoregressiven Filter $a^{-1}(B)$ und einen nichtstationären Summationsfilter S^d geht, wobei³⁾

$$(4.17) \quad S^d Z_t = (1 - B)^{-d} Z_t = X_t$$



In anderer Sichtweise läßt sich ein ARIMA-Modell als ein Instrument verstehen, den nichtstationären Prozeß X_t zu weißem Rauschen U_t zu transformieren: " ... we can regard it as a device for transforming the highly dependent, and possibly nonstationary process ... , to a sequence of uncorrelated random variables ... ; that is, for transforming the process to white noise"⁴⁾.

- 1) Vgl. Box/Jenkins (1976), S. 50 f., Granger/Newbold (1977), S. 24. Für die Stationarität von Z_t ist die Invertibilitätsbedingung ohne Bedeutung. Die Zweckmäßigkeit der Invertibilitätsbedingung ist unten erläutert.
- 2) Vgl. Box/Jenkins (1976), S. 12.
- 3) Vgl. ibid., S. 89.
- 4) Ibid.

2. In der vorliegenden Untersuchung wird ausschließlich der Differenzenfilter $(1 - B)^d$ zur Beseitigung von Nichtstationarität verwendet. Dieses Transformations-Verfahren scheint - insbesondere mit $d = 1$ - die in ökonomischen Zeitreihen anzutreffende Form der Nichtstationarität in der Regel zumindestens in ausreichendem Umfang zu erfassen.¹⁾ Darüberhinaus kann die Einfachheit dieses Verfahrens als Vorteil gegenüber anderen, komplizierteren Verfahren zur Beseitigung von Nichtstationarität gewertet werden.²⁾

Die Wahl des Differenzenfilters $(1 - B)^d$ sollte nur im Sinne einer Approximierung verstanden werden, die nicht für alle Formen der Nichtstationarität die bestmögliche Lösung darstellen muß. In Abschnitt 6 sind einige der bei Verwendung dieses Differenzenfilters auftretenden Probleme angesprochen.

3. ARMA-Prozesse können als Repräsentationsform des "generellen linearen Prozesses"³⁾ betrachtet werden:

$$(4.18) \quad Z_t = (1 + v_1 B + v_2 B^2 + \dots) U_t$$

- 1) S. auch Granger/Newbold (1977), S. 107: "In our experience, differencing ... is almost always required to produce stationarity and models based on the differenced series generally provide superior representation to the low-order autoregressive processes traditionally favored by econometricians. Further evidence for this contention is provided by the typical spectral shape of economic time series." Pierce/Haugh (1977), S. 290: "There is ample evidence for choosing $(1 - B)^1$... for much economic data". Vgl. ferner Box/Jenkins (1976), S. 87.
- 2) S. auch Granger/Newbold (1977), S. 311: "... the number of possible nonstationary models is very large indeed and ... many cannot be analyzed given just a single realization over a limited time period. The analyst is therefore forced to consider those models that he has a chance of correctly analyzing from available data". Zu den bei der von Box/Cox (1964) empfohlenen Transformation auftretenden Problemen vgl. Chatfield/Prothero (1973b). Auch die Eignung einer logarithmischen Transformation ist - bei ökonomischen Zeitreihen - nicht unbestritten. Vgl. Chatfield/Prothero (1973a) und die dort anschließende Diskussion.
- 3) Vgl. Box/Jenkins (1976), S. 46.

wobei

$$(4.19) \quad \sum_{i=1}^{\infty} v_i^2 < \infty$$

Eine andere dem ARMA-Prozeß äquivalente Darstellung ist die der "invertierten" Form, in der Z_t als eine Linearkombination verzögerter Z_t -Werte und der gegenwärtigen stochastischen Größe U_t angesehen wird:¹⁾

$$(4.20) \quad Z_t = w_1 Z_{t-1} + w_2 Z_{t-2} + \dots + U_t$$

wobei

$$(4.21) \quad \sum_{i=1}^{\infty} w_i^2 < \infty$$

Die Entsprechung des ARMA-Prozesses und des generellen linearen Prozesses bzw. der invertierten Form beruht auf der Tatsache, daß eine infinite Lag-Verteilung durch eine rationale Lag-Verteilung mit finiter Parameterzahl mit jeder gewünschten Genauigkeit approximiert werden kann.²⁾

Die Operatorpolynome $a(B)$ und $b(B)$ approximieren $v(B)$ bzw. $w(B)$ aufgrund der Beziehungen:

$$(4.22) \quad a^{-1}(B)b(B) = v(B)$$

bzw.

$$(4.23) \quad a(B)b^{-1}(B) = (1 - w(B))$$

Aus der Gegenüberstellung mit dem generellen linearen Prozeß und der invertierten Form ergibt sich damit die Sparsamkeit der Parametrisierung als Vorzug des ARMA-Prozesses. Der generelle lineare Prozeß wie die invertierte Form wei-

1) Vgl. Box/Jenkins (1976), S. 47.

2) Vgl. Jorgenson (1966), S. 137 ff.

sen jeweils eine infinite Zahl von U_t - bzw. Z_t -Gliedern und damit eine infinite Zahl von Parametern v_i bzw. w_i auf, während im ARMA-Modell nur p autoregressive und q Moving Average-Parameter auftreten.

4. Die Präferenz von ARIMA- bzw. ARMA-Modellen gegenüber anderen "naiven" Modellen ergibt sich aus drei Gründen:

- ARMA-Prozesse können unter gewissen Voraussetzungen in bezug auf den Erzeugungsmechanismus der exogenen Variablen als Repräsentationsform ökonometrischer Modelle angesehen werden. Sie weisen damit enge Verwandtschaft zu kausalen Erklärungsmodellen auf.
- ARIMA- bzw. ARMA-Modelle haben in Bewertungen gegenüber anderen univariaten Modellen und ökonometrischen Modellen gute Resultate erzielt.
- Mit der von Box/Jenkins empfohlenen iterativen Strategie liegt ein umfassendes Konzept zur Modellierung von ARIMA- bzw. ARMA-Prozessen vor.¹⁾

Aufgrund der Bedeutung von ARIMA- bzw. ARMA-Modellen für die beiden empirischen Teile dieser Untersuchung sind diese Gründe im folgenden ausführlich erläutert.

422 Die Eignung univariater ARIMA- bzw. ARMA-Modelle als Maßstab

4221 Univariate ARMA-Prozesse als Repräsentationsform eines ökonometrischen Modells

Das Gleichungssystem eines ökonometrischen Modells sei in

- 1) S. auch Dhrymes et al. (1972), S. 315: "The procedure of Box and Jenkins ... may be particularly powerful in helping to identify the autoregressive procedures which would serve as "naive" alternatives to structural models".

Matrix-Notation wie folgt gegeben:¹⁾

$$(4.24) \quad \begin{bmatrix} \underline{A(B)} & \underline{C(B)} \\ \underline{O} & \underline{D(B)} \end{bmatrix} \begin{bmatrix} \underline{Y} \\ \underline{X} \end{bmatrix} = \begin{bmatrix} \underline{F(B)} \\ \underline{G(B)} \end{bmatrix} \begin{bmatrix} \underline{E} & \underline{N} \end{bmatrix}$$

wobei

$$\underline{Y}' = \begin{bmatrix} \underline{Y}_1 & \underline{Y}_2 & \dots & \underline{Y}_h \end{bmatrix}$$

$$\underline{Y}'_i = \begin{bmatrix} Y_{i1} & Y_{i2} & \dots & Y_{iT} \end{bmatrix}$$

$$\underline{X}' = \begin{bmatrix} \underline{X}_1 & \underline{X}_2 & \dots & \underline{X}_r \end{bmatrix}$$

$$\underline{X}'_j = \begin{bmatrix} X_{j1} & X_{j2} & \dots & X_{jT} \end{bmatrix}$$

$$\underline{E}' = \begin{bmatrix} \underline{E}_1 & \underline{E}_2 & \dots & \underline{E}_b \end{bmatrix}$$

$$\underline{E}'_i = \begin{bmatrix} E_{i1} & E_{i2} & \dots & E_{iT} \end{bmatrix}$$

$$\underline{N} = \begin{bmatrix} \underline{N}_1 & \underline{N}_2 & \dots & \underline{N}_r \end{bmatrix}$$

$$\underline{N}_j = \begin{bmatrix} N_{j1} & N_{j2} & \dots & N_{jT} \end{bmatrix}$$

$$i = 1, \dots, h$$

$$j = 1, \dots, r$$

$\underline{Y}$ ist die Matrix der endogenen, $\underline{X}$ die der exogenen Variablen, $\underline{E}$ und $\underline{N}$ sind die Matrizen der stochastischen Größen, wobei die $\underline{E}_i$ und $\underline{N}_j$ jeweils weißes Rauschen sind, und $\underline{A(B)}$, $\underline{C(B)}$, $\underline{D(B)}$, $\underline{F(B)}$ und $\underline{G(B)}$ sind jeweils Matrizen von Operatorpolynomen. $\underline{O}$ ist eine Nullmatrix. Es sei angenommen, alle Wurzeln der polynomischen Gleichungen

$$(4.25) \quad \begin{aligned} |\underline{A(B)}| &= 0 \\ |\underline{C(B)}| &= 0 \\ |\underline{D(B)}| &= 0 \end{aligned}$$

1) Vgl. zum folgenden Zellner/Palm (1974), S. 18 - 20, Prothero/Wallis (1976), S. 469 f., Granger/Newbold (1977), S. 217 f.

$$\begin{aligned} \underline{F(B)} &= 0 \\ \underline{G(B)} &= 0 \end{aligned}$$

lügen außerhalb des Einheitskreises. Ansonsten gelten die üblichen Annahmen für ökonometrische Modelle.¹⁾

Der erste Block des Gleichungssystems (4.24) stellt die strukturelle Form eines ökonometrischen Modells dar. Zusätzlich zu der üblichen Darstellung ökonometrischer Modelle ist hier der Erzeugungsmechanismus der exogenen Variablen (zweiter Block des Gleichungssystems (4.24)) aufgeführt, wobei unterstellt ist, die X_{jt} ($t = 1, \dots, T$) besäßen jeweils univariate ARMA-Repräsentation.

Aus (4.24) läßt sich einfach ableiten:

$$(4.26) \quad \underline{A(B)} \underline{Y} = \underline{A^*(B)K(B)U}$$

wobei

$$\begin{aligned} \underline{A^*(B)} & \text{ Matrix der Adjunkten von } \underline{A(B)} \\ \underline{K(B)} &= \begin{bmatrix} \underline{F(B)} & -\underline{L(B)} \end{bmatrix} \\ \underline{L(E)} &= \underline{C(B)D^{-1}(B)G(B)} \\ \underline{U'} &= \begin{bmatrix} \underline{E} & \underline{N} \end{bmatrix} \end{aligned}$$

(4.26) kann in Anlehnung an Tinbergen²⁾ als ein System von Finalgleichungen bezeichnet werden. Eine einzelne Gleichung in (4.26) lautet:

$$(4.27) \quad \underline{A(B)} \underline{Y}_i = \underline{m_i(B)U}$$

wobei $\underline{m_i(B)}$ die i -te Zeile von $\underline{A^*(B)K(B)}$ ist.

1) Vgl. z.B. Granger/Newbold (1977), S. 192 ff.

2) Vgl. Tinbergen (1939).

Als das wesentliche Ergebnis dieser Ableitung kann festgehalten werden, daß (4.27) als univariates ARMA-Modell für $\underline{Y}_i$ verstanden werden kann. Unter den getroffenen Voraussetzungen können univariate ARMA-Modelle somit als Finalgleichungen ökonometrischer Modelle angesehen werden.¹⁾ Diese Analogie macht ARMA-Modelle zu einem nabeliegenden Instrument für Prognose-Bewertungen: "... one would expect a correctly specified econometric model, with its explicit representation of the various interrelationships and restrictions, to perform better than the univariate time series model. Since in forecast comparisons the particular features of a common autoregressive operator and cross-correlated disturbances have not been employed in estimating the univariate models, placing them under a statistical handicap, any outperforming of the econometric models would suggest that the latter are deficient in their dynamic and stochastic specification".²⁾

4222 Die Prognosegüte univariater ARIMA- bzw. ARMA-Modelle im Vergleich zu der anderer univariater und ökonometrischer Modelle

1) Vgl. Zellner/Palm (1974), S. 19. Bemerkenswert ist, daß in (4.27) die autoregressiven Operatorpolynome der univariaten ARMA-Modelle für alle $\underline{Y}_i$ gleich sind. Im allgemeinen werden jedoch $A(B)$ und $\underline{m}_i(B)$ gemeinsame Faktoren enthalten, die gekürzt werden können, sodaß die Ordnung und die Parameter der autoregressiven Operatorpolynome dann doch von Variable zu Variable verschieden sein werden. Gemeinsame Faktoren werden insbesondere dann auftreten, wenn das zugrundeliegende ökonometrische Modell rekursive Elemente aufweist. Vgl. hierzu Orcutt (1949), S. 2, Zellner/Palm (1974), S. 19, Prothero/Wallis (1976), S. 470, Granger/Newbold (1977), S. 217 f. Zu beachten ist ferner, daß die stochastischen Größen der univariaten ARMA-Modelle über die einzelnen Gleichungen hinweg korreliert sein werden. Vgl. Granger/Newbold (1977), S. 217.

2) Prothero/Wallis (1976), S. 471.

1. In einer Monte Carlo-Studie von Newbold/Granger¹⁾ ist die Prognosegüte von ARIMA-Modellen in diversen Post-Sample-Perioden verglichen mit der anderer univariater Modelle, und zwar

- einer "exponential smoothing"-Methode von Holt und Winters (im folgenden als "HW" bezeichnet);
- einer "stepwise autoregression"-Methode (im folgenden als "SA" bezeichnet).²⁾

Der Untersuchung liegen 106 ökonomische Zeitreihen zugrunde 26 davon auf Quartals-, die restlichen auf Monatsbasis. Nach Newbold/Granger sind die durchschnittlichen quadrierten Prognosefehler der ARIMA-Modelle überwiegend im Bereich von 60 - unter 100 % derjenigen der HW- und SA-Modelle.³⁾ Die Autoren stellen fest: "... the Box-Jenkins forecasts do seem to be better than those derived from ... the Holt-Winters method and stepwise autoregression ... for a sizeable majority of the time series in our sample"⁴⁾

In einer Studie von Reid sind die Ergebnisse von Newbold/Granger für eine Anzahl anderer univariater Methoden bestätigt.⁵⁾

2. In Tabelle 3 sind in gekürzter Form die Ergebnisse einiger Untersuchungen ausgewiesen, in denen die Prognosegüte einiger ökonometrischer Modelle mit der von ARIMA-Modellen verglichen ist. Es ist darauf verzichtet, solche Untersuchungen zu nennen, deren "naives" Alternativmodell - obwohl zur Klasse der ARIMA-Modelle gehörig - nicht mit-

1) Vgl. Newbold/Granger (1974).

2) Zur Beschreibung dieser Methoden vgl. Newbold/Granger (1974), S. 134 f.

3) Vgl. ibid., S. 138.

4) Ibid., S. 143. Zur Terminologie: "Box-Jenkins" entspricht hier ARIMA-Modellen.

5) Vgl. Reid (1969). Zitiert nach Granger/Newbold (1977), S. 180.

Tabelle 3

Zusammenfassung einiger Ergebnisse von Prognoseevalulierungen: Ökonometrische Modelle vs. univariate ARIMA-Modelle

Autor	Ökonometrisches Modell	Zahl der zu prognostizierenden Variablen	überlegenes Modell in der	Post-Sample-Periode	
				Sample-Periode	ökonomisches Modell
Lenthold et al. (1970)	Das zugrundeliegende Modell besteht aus zwei Gleichungen, die Angebot und Nachfrage erklären	2	entf.		
Naylor et al. (1972)	Wharton	4	entf.		ARIMA
Nelson (1972)	FRB-MIT-PENN	14		FRB-MIT-PENN	ARIMA
Hirsch et al. (1974)	BEA	8	entf.		BEA
Narasimham et al. (1974)	BEA	1	entf.		Für Prognose-distanz $J = 1, 3$: ARIMA, für $J = 2, 4$: BEA
Cooper/Nelson (1975)	1. FRB-MIT-PENN 2. St. Louis	jeweils 6		1. FRB-MIT-PENN 2. Unentschied.	1. ARIMA 2. Unentschied.
Prothero/Wallis (1976)	Hendry	6		Hendry	entf.

hilfe der von Box/Jenkins empfohlenen Strategie ermittelt wird.¹⁾

Das Kriterium für den Nachweis der Überlegenheit in den beiden letzten Spalten von Tabelle 3 ist einfach: jene Methode, die die Mehrzahl der Variablen aufgrund der von den jeweiligen Autoren verwendeten statistischen Maßgröße besser prognostiziert, wird als überlegen bezeichnet. Das Ausmaß der Überlegenheit wird hier ebensowenig beurteilt wie die Eignung der statistischen Maßgröße. Es ist nur ein grober, keinen Anspruch auf Repräsentativität erhebender Überblick über einige bisherige Evaluierungen beabsichtigt.

Wie Tabelle 3 zeigt, besitzen ARIMA-Modelle vor allem in Post-Sample-Perioden eine Prognosegüte, die an die ökonometrischer Modelle heranreicht. Dieses Ergebnis ist umso beeindruckender, als ökonometrische Modelle der hier vorgestellten Form ihre Spezifikation aus ökonomischen Theorien herleiten und - mit Ausnahme des Modells von Leuthold et al. - eine Vielzahl von Variablen verwenden. Dagegen berücksichtigen ARIMA-Modelle - ohne bezug zur ökonomischer Theorie - nur die Vergangenheit der zu prognostizierenden Zeitreihe.

3. Die zitierten Ergebnisse können keine letzte Entscheidung über die Güte von ARIMA-Prognosen im Vergleich zu der der Prognosen anderer univariater oder ökonometrischer Modelle darstellen. Sie verdienen jedoch als empirische Belege für die Nützlichkeit von ARIMA-Modellen in konkreten Fällen angeführt zu werden.

1) Ein Beispiel hierfür ist bei Cooper (1972) zu finden, der eine "stepwise autoregression"-Methode anwendet, um die optimale autoregressive Repräsentation einer Zeitreihe zu gewinnen. Aufgrund des in Sample- und Post-Sample-Periode durchgeführten Vergleichs mit bekannten ökonometrischen Modellen stellt Cooper fest: "... the econometric models are not, in general, superior to purely mechanical methods of forecasting". Cooper (1972), S. 920

423 Die iterative Box/Jenkins-Strategie zur Identifikation¹⁾
und Schätzung univariater ARIMA- bzw. ARMA-Modelle

4231 Einleitung

Box/Jenkins empfehlen eine iterative Strategie zur Identifikation und Schätzung von ARIMA- bzw. ARMA-Modellen.²⁾

Diese Strategie besteht aus drei Phasen:

- In der Identifikations-Phase werden Annahmen in bezug auf die Ordnung (p,d,q) bzw. (p,q) des zugrundeliegenden ARIMA- bzw. ARMA-Prozesses getroffen und grobe Anfangsschätzungen der Parameter erstellt.
- Das vorläufig identifizierte Modell wird in der zweiten Phase mithilfe effizienter Verfahren geschätzt, wobei die in der ersten Phase ermittelten groben Anfangsschätzungen der Parameter einbezogen werden.
- Ein System von "Diagnostic Checks" überprüft in der dritten Phase die Adäquanz des in den beiden ersten Phasen identifizierten und geschätzten Modells.

-
- 1) Hier und im folgenden wird der Begriff "Identifikation" in einem anderen als in dem in der Ökonometrie üblichen Sinne verwendet. Identifikation im ökonometrischen Sinne bezieht sich auf die Schätzung der Parameter der strukturellen Form eines ökonometrischen Modells: "The econometric identification problem ... relates to finding a unique model, of a structural form, compatible with the joint density function of the given data". Granger/Newbold (1977), S. 219. Dagegen ist die Identifikation im Rahmen der Strategie von Box/Jenkins auf die Bestimmung der Ordnung (p,d,q) bzw. (p,q) eines ARIMA- bzw. ARMA-Modells gerichtet: "... to the time series analyst, the identification problem is to find, based on the evidence of the data, appropriate orders for the lags used in his model". Granger/Newbold (1977), S. 219.
- 2) Zur Box/Jenkins-Strategie vgl. z.B. Nelson (1973), Anderson (1975), Box/Jenkins (1976), Pindyck/Rubinfeld (1976), S. 452 ff., Granger/Newbold (1977), S. 71 ff.

Falls die Diagnostic Checks die Adäquanz des Modells nicht bestätigen, wird ein neuer Zyklus von Identifikation, Schätzung und Diagnostic Checks eingeleitet. Das iterative Verfahren wird fortgesetzt, bis die Diagnostic Checks eine befriedigende Anpassung des identifizierten und geschätzten Modells an die untersuchte Zeitreihe feststellen.¹⁾

Der Leitgedanke der Modellierungsphilosophie von Box/Jenkins ist das Prinzip sparsamer Parametrisierung ("principle of parsimony").²⁾ Bei der Wahl eines Modells zur Beschreibung einer Zeitreihe sollte dem Modell mit der sparsamsten Verwendung von Parametern der Vorzug gegeben werden, da ein Überfluß an Parametern zu ineffizienten Schätzungen führen kann.³⁾

Als Ziel der iterativen Strategie von Box/Jenkins kann somit der Versuch bezeichnet werden, ein Modell aus der Klasse der ARIMA- bzw. ARMA-Prozesse herzuleiten, das mithilfe sparsamer Parametrisierung eine adäquate Beschreibung einer beobachteten Zeitreihe ermöglicht.

Im folgenden sind die wesentlichen Inhalte der drei Phasen der iterativen Strategie von Box/Jenkins wiedergegeben, soweit sie für die anschließende empirische Analyse von Bedeutung sind. Eine Würdigung saisonaler Modelle unterbleibt, da die Grundgedanken der Box/Jenkins-Strategie hier sinngemäß angewendet werden können.

- 1) Eine graphische Darstellung des iterativen Zyklus von Identifikation, Schätzung und Diagnostic Checks ist bei Box/Jenkins (1976), S. 19, ausgewiesen.
- 2) S. auch Box/Jenkins (1976), S. 17: "It is important, in practice, that we employ the smallest possible number of parameters for adequate representation", *ibid.*, S. 18: "Our objective ... must be to obtain adequate but parsimonious models". S. auch Tukey (1961), S. 202: "This can be boldly stated as the Principle of Parsimony, viz. it may pay not to describe in the analysis the complexities that are really present in the situation". Whittle (1951), S. 7: "Simplicity is the criterion which we endeavor to follow, and normally we fit a scheme involving relatively few parameters ...".
- 3) Vgl. Box/Jenkins (1976), S. 340.

4232 Die Identifikation der Ordnung (p.d.o) bzw. (p.c)
eines ARIMA- bzw. ARMA-Modells

42321 Die Autokorrelationen und partiellen Autokorrelationen als Grundlage der Identifikation

1. Box/Jenkins messen den Autokorrelationen und partiellen Autokorrelationen einer Zeitreihe zentrale Bedeutung für die Identifikation der Ordnung eines ARIMA- bzw. ARMA-Modells bei.¹⁾

Die Autokorrelationen $r_{ZZ}(k)$ des stationären stochastischen Prozesses Z_t sind definiert als:²⁾

$$(4.28) \quad r_{ZZ}(k) = \frac{E((Z_t - E(Z_t))(Z_{t-k} - E(Z_t)))}{(E(Z_t - E(Z_t))^2 E(Z_{t-k} - E(Z_t))^2)^{1/2}}$$

Da Z_t stationär ist, gilt:

$$E(Z_t - E(Z_t))^2 = E(Z_{t-k} - E(Z_t))^2 = \sigma_Z^2$$

1) Auf die Nützlichkeit der Autokorrelationen wird auch von Whittle verwiesen: "The correlogram is only one possible function of the data, so one may ask why it should be thus favoured. The principal reason is perhaps that it is the most informative statistic which does not involve moments of the data higher than the second order. Both from the point of view of computation and of sampling sensitivity, higher moments are undesirable. Furthermore, usual spectral theory makes no assumptions on process moments of order higher than the second, so that the correlogram possesses all information relevant to the spectrum, knowledge of which largely determines the structure of the process if it is a linear one". Whittle (1951), S. 25. Zur Terminologie: correlogram = Autokorrelogramm.

2) Vgl. Jenkins/Watts (1968), S. 155, Box/Jenkins (1976), S. 28, Pindyck/Rubinfeld (1976), S. 437, Granger/Newbold (1977), S. 5. Die hier gewählte Definition folgt der bei Granger/Newbold, indem Z_{t-k} anstelle von Z_{t-k} verwendet wird. Da $r_{ZZ}(k) = r_{ZZ}(-k)$, ist dieser Unterschied belanglos.

und daher

$$(4.29) \quad r_{ZZ}(k) = \frac{E((Z_t - E(Z_t))(Z_{t-k} - E(Z_t)))}{\sigma_Z^2}$$

Natürlich ist $r_{ZZ}(0) = 1$.

Die partiellen Autokorrelationen a_{KK} ergeben sich als Koeffizienten der $r_{ZZ}(k-K)$ in der Differenzengleichung K-ter Ordnung:¹⁾

$$(4.30) \quad r_{ZZ}(k) = a_{K1}r_{ZZ}(k-1) + \dots + a_{KK}r_{ZZ}(k-K)$$

$k = 1, \dots, K$

2. Es ist zu fragen, inwieweit das Autokorrelogramm eines ARMA-Prozesses einen eindeutigen Rückschluss auf die Ordnung (p, q) zuläßt. Falls keine Eindeutigkeit gegeben wäre, ist die Verwendung des Autokorrelogramms in der Identifikationsphase von geringem Nutzen. Es lassen sich hierzu die folgenden Feststellungen treffen:

- ein ARMA-Prozeß besitzt nur ein Autokorrelogramm;²⁾
- es gibt keine zwei stationären und invertiblen ARMA-Prozesse, die das gleiche Autokorrelogramm aufweisen;³⁾
- die Multiplikation des autoregressiven und des Moving Average-Teils eines ARMA-Modells mit dem gleichen Operatorpolynom hat keinen Einfluß auf das Autokorrelogramm.⁴⁾

Die zweite Aussage weist implizit auf die Bedeutung der Invertibilität hin. Es gibt eine Vielzahl stationärer, aber nichtinvertibler ARMA-Prozesse, die das gleiche Autokorre-

1) Vgl. Box/Jenkins (1976), S. 64.

2) Vgl. Granger/Newbold (1977), S. 81.

3) Vgl. Box/Jenkins (1976), S. 197, Granger/Newbold (1977), S. 82.

4) Vgl. Granger/Newbold (1977), S. 82.

logramm besitzen; nur stationäre ARMA-Prozesse, die auch invertibel sind, haben ein unverwechselbares Autokorrelogramm.

Die dritte Feststellung scheint der zweiten zu widersprechen. Tatsächlich besitzen die Prozesse

$$a(B)Z_t = b(B)U_t$$

und

$$(1 - eB)a(B)Z_t = (1 - eB)b(B)U_t$$

für $-1 < e < 1$ das gleiche Autokorrelogramm.¹⁾ Allerdings handelt es sich hier nicht um zwei verschiedene ARMA-Prozesse, sondern beide Male um den gleichen, da das Operatorpolynom $(1 - eB)$ durch Kürzen entfernt werden kann.

Das hier angesprochene Problem der Modell-Multiplizität ("model multiplicity")²⁾ ist jedoch nicht immer so einfach erkennbar und lösbar; es sind Fälle denkbar, in denen ARMA-Modelle unterschiedlicher Ordnungen den gleichen Prozeß beschreiben, ohne daß dies offenkundig wäre.³⁾ Um der Gefahr der Modell-Multiplizität zu entgehen, zielt die Strategie von Box/Jenkins gerade in der Identifikations-Phase auf die Wahl eines sparsam parametrisierten Modells: "A principal reason for going through the identification procedure prior to fitting the model, is to avoid difficulties arising from parameter redundancy, or to be more positive, to achieve parsimony in parameterization".⁴⁾

1) Vgl. Granger/Newbold (1977), S. 82.

2) Vgl. Box/Jenkins (1976), S. 195.

3) Vgl. *ibid.*, S. 248.

4) *Ibid.*, S. 249. S. auch Granger/Newbold (1977), S. 83: "The possibility of multiple solutions arising from multiplication of both sides ... by a common factor should caution against the selection of overelaborate models at the identification stage. The aim of model identification should be to choose the simplest (in terms of fewest coefficients) model compatible with the particular autocorrelation structure exhibited by the data."

42322 Das Autokorrelogramm eines ARIMA-Prozesses für
 $d > 0$

Die Autokorrelationen $r_{XX}(k)$ des homogen nichtstationären ARIMA-Prozesses X_t weisen ein überwiegend gleichmäßiges Erscheinungsbild auf; auf hohem Niveau beginnend sinken sie mit ansteigendem Lag k nur langsam gegen null ab.¹⁾ Dies läßt sich anschaulich mit einem Beispiel von Box/Jenkins belegen.²⁾ Es sei das Bildungsgesetz eines stochastischen Prozesses gegeben durch

$$(4.31) \quad (1 - a_1 B - \dots - a_{p'} B^{p'}) X_t = U_t$$

U_t sei weißes Rauschen. Es gilt dann für die Autokorrelationen $r_{XX}(k)$:³⁾

$$(4.32) \quad r_{XX}(k) = A_1 G_1^k + \dots + A_{p'} G_{p'}^k$$

wobei

G_i^{-1} Wurzeln der polynomischen Gleichung
 $(1 - a_1 B - \dots - a_{p'} B^{p'}) = 0$;

A_i Konstanten, die sich aus den Anfangswerten von $r_{XX}(k)$ ergeben;

$i = 1, \dots, p'$

Stationarität von X_t impliziert, daß die G_i alle innerhalb des Einheitskreises liegen; sofern die G_i nicht zu nahe am Einheitskreis liegen, werden die $r_{XX}(k)$ mit ansteigendem k rasch absinken. Falls ein G_i , z.B. G_1 , nahe am Einheitskreis liegt, mit $G_1 = (1 - ks)$, wobei s eine kleine posi-

1) Vgl. z.B. Hannan (1970), S. 13, Box/Jenkins (1976), S. 174 f., Granger/Newbold (1977), S. 40 f.

2) Vgl. Box/Jenkins (1976), S. 174.

3) Vgl. ibid.

tive Größe ist, dann gilt für große k :

$$(4.33) \quad r_{XX}(k) \approx A_1(1 - ks)$$

Die $r_{XX}(k)$ werden also nur sehr verzögert absinken; das Autokorrelogramm wird über weite Bereiche ein gleichförmiges Erscheinungsbild aufweisen. Andere Gesetzmäßigkeiten des stochastischen Prozesses werden vollständig vom Aspekt der Nichtstationarität dominiert und sind nicht aus den $r_{XX}(k)$ herauslesbar.¹⁾

Generell weisen die Autokorrelogramme der Prozesse

$$(1 - B)^d - i X_t$$

$$(i = 1, \dots, (d - 1), d)$$

ein solches Erscheinungsbild auf, so daß das erste Autokorrelogramm sukzessiver Differenzen von X_t , dessen Koeffizienten rasch absinken, die Zahl d der für Stationarität notwendigen Differenzen bestimmt: "It follows that a plausible technique for determining the value d is to form correlograms for the process differenced once, twice, etc. until a correlogram is obtained that does not display the shape found for integrated processes"²⁾.

42323 Das Autokorrelogramm ausgewählter ARMA-Prozesse

Die Autokorrelationen und partiellen Autokorrelationen des stationären und invertiblen ARMA-Prozesses Z_t der Ordnung (p, q) werden nachfolgend für drei mögliche Kombinationen von p und q beschrieben.

1) Vgl. Granger/Newbold (1977), S. 75.

2) Ibid., S. 41. Zur Terminologie: correlogram = Autokorrelogramm.

1. $p \neq 0, q = 0$

Die Autokorrelationen des ARMA-Prozesses Z_t , wobei

$$(1 - a_1 B - \dots - a_p B^p) Z_t = U_t$$

gehören einer Differenzengleichung der Ordnung p :¹⁾

$$(4.34) \quad (1 - a_1 B - \dots - a_p B^p) r_{ZZ}(k) = 0$$

(B operiert an k)

Die Lösung zu (4.34) ist:²⁾

$$(4.35) \quad r_{ZZ}(k) = A_1 G_1^k + \dots + A_p G_p^k$$

wobei

G_i^{-1} Wurzeln der polynomischen Gleichung
 $(1 - a_1 B - \dots - a_p B^p) = 0$;

A_i Konstanten, die sich aus den Anfangswerten
 von $r_{ZZ}(k)$ ergeben;

$i = 1, \dots, p$

Da Z_t stationär ist, liegen alle G_i innerhalb des Einheitskreises. Es können drei Arten von G_i unterschieden werden, die jeweils unterschiedlichen Einfluß auf das Verhalten der $r_{ZZ}(k)$ ausüben:³⁾

- G_i real und positiv: $A_i G_i^k$ sinkt mit steigendem k geometrisch gedämpft ab;
- G_i real und negativ: $A_i G_i^k$ sinkt mit steigendem k oszillierend geometrisch gedämpft ab;

1) Vgl. Box/Jenkins (1976), S. 54.

2) Vgl. ibid., S. 55.

3) Vgl. ibid.

- ein Paar G_i, G_j ist konjugiert komplex: ¹⁾ $A_i G_i^k$
und $A_j G_j^k$ sinken mit steigendem k sinusförmig ab.

Die in jedem Fall auftretende Dämpfung der $r_{ZZ}(k)$ ist für einen stationären autoregressiven Prozeß ein typisches Merkmal. Die $r_{ZZ}(k)$ sind - ebenso wie die Z_t - mit allen vorangehenden Gliedern ihrer Reihe korreliert, wenn auch bei ansteigendem k in schnell absinkendem Maße. Da alle G_i zum Verhalten der $r_{ZZ}(k)$ beitragen, kann eine Mischung aus jeweils gedämpften geometrischen, oszillierend geometrischen und sinusförmigen Schwingungen das Erscheinungsbild der Autokorrelationen bestimmen. Das Autokorrelogramm wird in diesem Falle keine geeignete Entscheidungsgrundlage für die Identifikation der Ordnung p des autoregressiven Prozesses Z_t abgeben.

p kann jedoch aus den partiellen Autokorrelationen a_{KK} abgelesen werden. Es ist zu bedenken, daß für einen autoregressiven Prozeß der Ordnung p die a_{KK} in (4.30) null sind für $k, K \geq (p + 1)$. Das letzte $a_{KK} \neq 0$ bestimmt somit die Ordnung p .

2. $p = 0, q \neq 0$

Die Autokorrelationen des ARMA-Prozesses Z_t , wobei

$$Z_t = (1 - b_1 B - \dots - b_q B^q) U_t$$

sind für $k \leq q$ eine komplizierte Funktion der Parameter b_i ($i = 1, \dots, q$): ²⁾

-
- 1) Da die a_i ($i = 1, \dots, p$) real sind, treten komplexe Wurzeln stets paarweise auf. Vgl. auch Granger/Newbold (1977), S. 9.
 - 2) Vgl. Box/Jenkins (1976), S. 68.

$$(4.36) \quad r_{ZZ}(k) = \frac{-b_k + b_1 b_{k+1} - \dots + b_{q-k} b_q}{1 + b_1^2 + \dots + b_q^2}$$

Für $k > q$ gilt:

$$(4.37) \quad r_{ZZ}(k) = 0$$

Das abrupte Abfallen der Autokorrelationen für $k = (q + 1)$ ist ein Wesensmerkmal eines Moving Average-Prozesses der Ordnung q . Das "Gedächtnis" des Prozesses umfaßt nur q Perioden; Z_t und Z_{t-k} sind nur für $k \leq q$ miteinander korreliert. Aus dem Verhalten der Autokorrelationen für $k = (q + 1)$ läßt sich der Rückschluß auf q ziehen: das letzte $r_{ZZ}(k) \neq 0$ bestimmt die Ordnung q .

Die partiellen Autokorrelationen des Moving Average-Prozesses der Ordnung q verhalten sich analog den Autokorrelationen eines autoregressiven Prozesses der Ordnung q ; d.h. nach Maßgabe der Wurzeln der polynomischen Gleichung¹⁾

$$(1 - b_1 B - \dots - b_q B^q) = 0.$$

3. $p \neq 0$, $q \neq 0$

Die Autokorrelationen des ARMA-Prozesses Z_t , wobei

$$(1 - a_1 B - \dots - a_p B^p) Z_t = (1 - b_1 B - \dots - b_q B^q) U_t$$

gehören für $k \leq q$ dem folgenden Bildungsgesetz:²⁾

$$(4.38) \quad (1 - a_1 B - \dots - a_p B^p) r_{ZZ}(k) = (1 - b_1 B - \dots - b_q B^q) r_{UZ}(k)$$

1) Vgl. Nelson (1973), S. 83.

2) Vgl. Box/Jenkins (1976), S. 74.

wobei

$$(4.39) \quad r_{UZ}(k) = \frac{E(U_t Z_{t-k})}{(E(U_t)^2 E(Z_t)^2)^{1/2}}$$

$r_{UZ}(k)$ ist also die Kreuzkorrelation zwischen U_t und Z_{t-k} .¹⁾

Da

$$(4.40) \quad r_{UZ}(k) = 0 \quad k > q$$

gilt für $k \geq (q + 1)$

$$(4.41) \quad (1 - a_1 B - \dots - a_p B^p) r_{ZZ}(k) = 0$$

Die Autokorrelationen des ARMA-Prozesses der Ordnung (p, q) folgen demnach für $k \leq q$ einem Bildungsgesetz, das in komplizierter Weise von den p autoregressiven und q Moving Average-Parametern bestimmt wird. Für $k \geq (q + 1)$ wird das Erscheinungsbild der Autokorrelationen von den realen und/oder konjugiert komplexen Wurzeln der polynomischen Gleichung

$$(1 - a_1 B - \dots - a_p B^p) = 0$$

geprägt.

Die partiellen Autokorrelationen a_{KK} des ARMA-Prozesses der Ordnung (p, q) entsprechen für $k \geq (p + 1)$ denen eines Moving Average-Prozesses der Ordnung q .

4. Die Aussagefähigkeit der Autokorrelationen und partiellen Autokorrelationen für die Identifikation der Ordnung

- 1) Zur Definition der Kreuzkorrelation vgl. Jenkins/Watts (1968), S. 325, Box/Jenkins (1976), S. 373, Pindyck/Rubinfeld (1976), S. 437.

(p,q) eines stationären und invertiblen ARMA-Prozesses können wie folgt zusammengefaßt werden: gedämpfte Schwingungen der Autokorrelationen weisen auf den autoregressiven Teil, gedämpfte Schwingungen der partiellen Autokorrelationen auf den Moving Average-Teil hin. Abruptes Abfallen der Autokorrelationen erlaubt den Schluß auf die Ordnung q des Moving Average-Teils, abruptes Abfallen der partiellen Autokorrelationen erlaubt den Schluß auf die Ordnung p des autoregressiven Teils.

42324 Die statistischen Eigenschaften der Schätzungen der Autokorrelationen und partiellen Autokorrelationen

In aller Regel sind die Autokorrelationen und partiellen Autokorrelationen der Prozesse, die für die Erzeugung ökonomischer Reihen verantwortlich sind, unbekannt; sie müssen aufgrund einer Realisation geschätzt werden.

1. Für die Schätzungen der Autokorrelationen nichtstationärer Prozesse gilt weitgehend das für die theoretischen Autokorrelationen selbst festgestellte: sie sinken mit ansteigendem Lag k nur langsam ab; das Autokorrelogramm weist ein gleichmäßiges Erscheinungsbild auf.¹⁾ Allerdings müssen die geschätzten Autokorrelationen nicht notwendigerweise auf hohem Niveau (nahe bei eins) beginnen.²⁾

2. Die in einer Realisation des stationären und invertiblen ARMA-Prozesses Z_t gemessenen Schätzungen der Autokorrelationen $r_{ZZ}(k)$ haben Verteilungseigenschaften, die die Identifikation der Ordnung (p,q) erschweren können. Eine kon-

1) Vgl. Box/Jenkins (1976), S. 175, Granger/Newbold (1977), S. 75.

2) Vgl. Granger/Newbold (1977), S. 75.

sistente Schätzung von $r_{ZZ}(k)$ ist die in der Realisation z_t ($t = 1, \dots, T$) von Z_t gemessene Autokorrelation $r_{zz}(k)$, die definiert ist als¹⁾

$$(4.42) \quad r_{zz}(k) = \frac{\sum_{t=k}^T (z_t - \bar{z}_t)(z_{t-k} - \bar{z}_t)}{\sum_{t=k}^T (z_t - \bar{z}_t)^2}$$

$\bar{z}_t$ ist der Mittelwert der z_t .

Die Varianz der $r_{zz}(k)$ ist von allen $r_{ZZ}(k)$ abhängig, wie Bartlett's Formel zu entnehmen ist:²⁾

$$(4.43) \quad \text{var}(r_{zz}(k)) \approx \frac{1}{T} \sum_{v=-\infty}^{\infty} (r_{ZZ}^2(v) + r_{ZZ}(v)r_{ZZ}(v+2k) + 2r_{ZZ}^2(k)r_{ZZ}(v) - 4r_{ZZ}(k)r_{ZZ}(v)r_{ZZ}(v-k))$$

Für solche Lags j , von denen an die theoretischen Autokorrelationen null sind, gilt:

$$(4.44) \quad \text{var}(r_{zz}(k)) \approx \frac{1}{T} \left(1 - 2 \sum_{v=1}^j r_{ZZ}^2(v) \right)$$

Die $r_{zz}(k)$ sind untereinander korreliert, wiederum in Abhängigkeit von den $r_{ZZ}(k)$:

$$(4.45) \quad \text{cov}(r_{zz}(k)r_{zz}(k+1)) \approx \frac{1}{T} \sum_{v=-\infty}^{\infty} (r_{ZZ}(v)r_{ZZ}(v-1) + r_{ZZ}(v)r_{ZZ}(v+2k-1) + 2r_{ZZ}(k)r_{ZZ}(k+1)r_{ZZ}^2(v))$$

1) Vgl. Jenkins/Watts (1968), S. 180, Box/Jenkins (1976), S. 32.

2) Vgl. Bartlett (1962), S. 289. Die dort angegebene Formel ist für die Gleichungen (4.43) - (4.47) nach Maßgabe der Besonderheit jedes Falles abgeändert. Es ist unterstellt, T sei groß gegenüber k .

$$\begin{aligned}
& - 2r_{ZZ}(k)r_{ZZ}(v)r_{ZZ}(k+v+1) \\
& - 2r_{ZZ}(k+1)r_{ZZ}(v)r_{ZZ}(v+1))
\end{aligned}$$

Wiederum gilt für solche Lags k , von denen an die theoretischen Autokorrelationen null sind:

$$(4.46) \quad \text{cov}(r_{ZZ}(k)r_{ZZ}(k+1)) \approx \frac{1}{T} \sum_{v=-\infty}^{\infty} r_{ZZ}(v)r_{ZZ}(v+1)$$

Falls $r_{ZZ}(k) = 0$ für alle $k \neq 0$, gilt:

$$\begin{aligned}
(4.47) \quad & \text{var}(r_{ZZ}(k)) \approx \frac{1}{T} \\
& \text{cov}(r_{ZZ}(k)r_{ZZ}(k+1)) \approx 0
\end{aligned}$$

Nur wenn die $r_{ZZ}(k) = 0$ für $k \neq 0$ sind, d.h. wenn Z_t weißes Rauschen ist, ist das in einer Realisation gemessene Autokorrelogramm frei von Verzerrungen aufgrund der Kovarianz der $r_{ZZ}(k)$. Falls dagegen einige $r_{ZZ} \neq 0$ für $k \neq 0$, besitzen die $r_{ZZ}(k)$ nach Maßgabe von Bartlett's Formel erhöhte Varianzen und Kovarianzen. Dies gilt auch für solche $r_{ZZ}(k)$, deren korrespondierenden theoretischen Werte null sind.

3. Die Schätzungen a_{kk} der partiellen Autokorrelationen a_{KK} sind unter der Hypothese, daß ein ARMA-Prozeß der Ordnung $(p,0)$ vorliegt, für $k \geq (p+1)$ approximiert unabhängig verteilt. Die Varianz der a_{KK} errechnet sich dann aus:¹⁾

$$(4.48) \quad \text{var}(a_{kk}) \approx \frac{1}{T}$$

4233 Schätzung des ARIMA- bzw. ARMA-Modells

Die in dieser Untersuchung identifizierten ARMA-Modelle, die jeweils die d -ten Differenzen von ARIMA-Modellen sind,

1) Vgl. Box/Jenkins (1976), S. 65.

sind mithilfe eines nichtlinearen Schätzverfahrens, das von Marquardt stammt,¹⁾ geschätzt.²⁾ Eine Besonderheit des hier verwendeten Computerprogramms ESTMAT³⁾ ist die "Rückprognose" ("Backforecast") der vor Beginn der Sample-Periode liegenden Beobachtungen.⁴⁾ Da nach den Gleichungen (4.12) und (4.14) gilt:

$$(4.49) \quad U_t = Z_t - a_1 Z_{t-1} - \dots - a_p Z_{t-p} - b_1 U_{t-1} - \dots - b_q U_{t-q}$$

können die T Schätzungen von U_t nur berechnet werden, wenn für $Z_0, Z_{-1}, \dots, Z_{1-p}, U_0, U_{-1}, \dots, U_{1-q}$ Schätzungen angesetzt werden. Die Technik des "Backforecasting" erlaubt Schätzungen mit größerer Effizienz, als wenn die vor Beginn der Sample-Periode liegenden Werte ohne Verwendung der Sample-Werte geschätzt würden.⁵⁾ Für mittlere Sample-Größen produziert der auf der "Backforecasting"-Technik beruhende Ansatz nahezu Maximum Likelihood-Schätzungen.⁶⁾

Für den Beginn des nichtlinearen Ansatzes müssen erste Schätzungen der Parameter a_i ($i = 1, \dots, p$) und b_j ($j = 1, \dots, q$) angegeben werden. Grobe Anfangsschätzungen der autoregressiven und Moving Average-Parameter lassen sich in der Identifikations-Phase aufgrund der geschätzten Autokorrelationen und partiellen Autokorrelationen gewinnen.⁷⁾ Hierzu kann für rein autoregressive Modelle das

1) Vgl. Marquardt (1963).

2) Ein nichtlineares Schätzverfahren ist notwendig, da die erste Ableitung von S, wobei

$$(4.50) \quad S = \sum ((1 - a_1 B - \dots - a_p B^p) Z_t + (b_1 B + \dots + b_q B^q) U_t)^2$$

nichtlinear in den a_i ($i = 1, \dots, p$) und b_j ($j = 1, \dots, q$) ist.

3) Eine Beschreibung dieses Programms findet sich bei Nelson (1973), S. 99 ff. und 223 f.

4) Vgl. hierzu Granger/Newbold (1977), S. 84 ff.

5) Vgl. ibid., S. 87.

6) Vgl. ibid.

7) Vgl. Nelson (1973), S. 89, Box/Jenkins (1976), S. 187 ff., Granger/Newbold (1977), S. 79 f.

System der Yule-Walker-Gleichungen verwendet werden, wobei für die $r_{ZZ}(k)$ die Schätzungen $\hat{r}_{ZZ}(k)$ eingesetzt werden.¹⁾ Erste Hinweise auf das Vorzeichen und die Größenordnung der autoregressiven Parameter lassen sich ferner aufgrund der partiellen Autokorrelationen geben. Wenn die Ordnung q des Moving Average-Teils ungleich null ist, kann Nelson gefolgt werden, der vorschlägt, die autoregressiven Parameter zunächst mithilfe des Systems der Yule-Walker-Gleichungen für $k > q$ zu schätzen. Die Moving Average-Parameter lassen sich dann grob mithilfe der Yule-Walker-Gleichungen für $k \leq q$ schätzen, wobei die im ersten Schritt gewonnenen Schätzungen der autoregressiven Parameter eingesetzt sind.²⁾

Die für lineare Schätzungen üblichen Tests sind für nicht-lineare Schätzungen im allgemeinen nicht gültig.³⁾ Insofern im folgenden dennoch Tests durchgeführt werden, dürfen sie nur als ungefähre Vergleichsmaße interpretiert werden.

4234 Diagnostic Checks

1. Box/Jenkins empfehlen als wichtigstes Element der Diagnostic Checks die Prüfung der Autokorrelationen der Residuen des identifizierten und geschätzten ARIMA- bzw. ARMA-Modells.¹⁾

Es ist zu bedenken, daß U_t in (4.12) weißes Rauschen ist, d.h. $r_{UU}(k) = 0$ für alle $k \neq 0$. Folgerichtig sollten die Residuen des identifizierten und geschätzten Modells ein Autokorrelogramm aufweisen, das dem der Realisation von weißem Rauschen entspricht.

Es ist zu unterscheiden zwischen den Residuen u_t , wobei

- 1) Vgl. Nelson (1973), S. 89, Box/Jenkins (1976), S. 189 f.
- 2) Vgl. Nelson (1973), S. 91, Granger/Newbold (1977), S. 79.
- 3) Vgl. Draper/Smith (1966), S. 282.

$$(4.51) \quad (1 - a_1 B - \dots - a_p B^p)(1 - b_1 B - \dots - b_q B^q) z_t = u_t$$

und den geschätzten Residuen $\hat{u}_t$, wobei

$$(4.52) \quad (1 - \hat{a}_1 B - \dots - \hat{a}_p B^p)(1 - \hat{b}_1 B - \dots - \hat{b}_q B^q) z_t = \hat{u}_t$$

Die $\hat{a}_i$ ($i = 1, \dots, p$) und $\hat{b}_j$ ($j = 1, \dots, q$) sind jeweils Schätzungen der a_i und b_j . Die u_t sind die Residuen der Realisation z_t , wenn die tatsächlichen Parameter der Operatorpolynome $a(B)$ und $b(B)$ bekannt sind, während bei $\hat{u}_t$ die Parameter geschätzt werden müssen.

Da U_t weißes Rauschen ist, sind die $r_{\hat{u}\hat{u}}(k)$ approximiert normal verteilt, mit Mittelwert null und Standardabweichung $n^{-1/2}$, wobei $n = (T - d)$. Regelmäßig sind jedoch nur die $\hat{u}_t$ bekannt,¹⁾ und zumindestens für kleine Lags k kann nach Durbin $n^{-1/2}$ die Standardabweichung der $r_{\hat{u}\hat{u}}(k)$ erheblich überschätzen.²⁾ Der Signifikanztest einzelner Koeffizienten besitzt damit für kleine Lags einen Bias zugunsten der Annahme, der zugrundeliegende Prozeß sei weißes Rauschen. Für mittlere und höhere Lags ist $n^{-1/2}$ jedoch eine brauchbare Approximierung der Standardabweichung der $r_{\hat{u}\hat{u}}(k)$.³⁾

2. Ein Test der $r_{\hat{u}\hat{u}}(k)$ über einen größeren Lag-Bereich ist mithilfe der von Box/Pierce entwickelten Test-Statistik Q möglich,⁴⁾ wobei

$$(4.53) \quad Q = (T - d) \sum_{k=1}^K r_{\hat{u}\hat{u}}^2(k)$$

1) Vgl. Box/Jenkins (1976), S. 290.

2) Vgl. Durbin (1970), S. 422.

3) Vgl. Box/Jenkins (1976), S. 290.

4) Vgl. Box/Pierce (1970).

Unter der Nullhypothese, daß U_t weißes Rauschen ist, folgt Q approximiert einer Chi-Quadrat-Verteilung mit $(K - p - q)$ Freiheitsgraden. Q kann somit zum Test der Adäquanz des identifizierten und geschätzten ARIMA- bzw. ARMA-Modells verwendet werden: wenn Q den kritischen Wert der Chi-Quadrat-Verteilung für die gewählte Irrtumswahrscheinlichkeit übersteigt, ist die Nullhypothese abzulehnen.

3. Falls der Test einzelner oder einer Gruppe von $r_{\hat{u}\hat{u}}(k)$ signifikante Abweichungen der $\hat{u}_t$ von weißem Rauschen indiziert, lassen sich aus den $r_{\hat{u}\hat{u}}(k)$ wiederum Hinweise auf die Neuformulierung des Modells gewinnen.¹⁾ Wenn nämlich U_t^0 in

$$(4.54) \quad a_0(B)(1 - B)^{d_0}X_t = b_0(B)U_t^0$$

nicht weißes Rauschen ist, sondern dem Bildungsgesetz

$$(4.55) \quad a_1(B)(1 - B)^{d_1}U_t^0 = b_1(B)U_t$$

gehört, wobei U_t weißes Rauschen ist, so läßt sich die Beziehung zwischen X_t und U_t wie folgt darstellen:

$$(4.56) \quad a_0(B)a_1(B)(1 - B)^{d_0}(1 - B)^{d_1}X_t = b_0(B)b_1(B)U_t$$

Hinweise auf $a_1(B)$, $b_1(B)$ und d_1 sollten sich aus der Inspektion der $r_{\hat{u}\hat{u}}(k)$ ergeben.

4. Ein weiteres wichtiges Instrument im Rahmen der Diagnostic Checks sind die Schätzungen der Kreuzkorrelationen $r_{UZ}(k)$. Natürlich muß gelten:

$$(4.57) \quad \underline{r_{UZ}(k)} = 0 \quad k > 0$$

1) Vgl. Box/Jenkins (1976), S. 298 f.

Das Erscheinungsbild der geschätzten Kreuzkorrelationen $r_{\hat{u}z}(k)$ sollte für $k > 0$ daher dem des Kreuzkorrelogramms von Realisationen unabhängiger Prozesse entsprechen.¹⁾

5. In der folgenden empirischen Analyse ist im Rahmen der Diagnostic Checks das Hauptaugenmerk jeweils auf das Autokorrelogramm der $\hat{u}_t$ gerichtet. Die Kreuzkorrelationen $r_{\hat{u}z}(k)$ sind zwar aufgeführt, jedoch in der Regel keiner ausführlichen Interpretation unterzogen. Diese Gewichtung - wie auch die Entscheidung, andere in der Literatur genannten Diagnostic Checks nicht zu verwenden -²⁾ ist im Interesse der Übersichtlichkeit der Darstellung getroffen.³⁾

4235 Zur Anwendung der iterativen Box/Jenkins-Strategie

1. Die iterative Modellierungsstrategie von Box/Jenkins liefert ein nützliches Instrumentarium zur Identifikation und Schätzung eines sparsam parametrisierten Modells aus der Klasse der ARIMA- bzw. ARMA-Prozesse. In der Identifikationsphase der Strategie, die auf dem Erscheinungsbild der geschätzten Autokorrelationen und partiellen Autokorrelationen beruht, wird jedoch regelmäßig noch keine eindeutige Entscheidung über die Ordnung (p,d,q) bzw. (p,q) möglich sein. Da die Autokorrelationen einer Realisation eines ARIMA- bzw. ARMA-Prozesses beträchtlichen Varianzen und Kovarianzen haben können, wird jeder Rückschluß auch mit Ungewißheiten behaftet sein.

Box/Jenkins empfehlen, zunächst mehrere Modelle, die aufgrund

- 1) Vgl. Nelson (1973), S. 115.
- 2) In erster Linie ist hier an die Technik des "Overfitting" zu denken, bei der einem identifizierten Modell bei der Schätzung weitere Parameter zugefügt werden. Vgl. Nelson (1973), S. 114, Box/Jenkins (1976), S. 286 f., Granger/Newbold (1977), S. 89 ff.
- 3) Darüberhinaus könnte wohl auch keine Liste von Diagnostic Checks für sich Vollständigkeit beanspruchen: "No system of diagnostic checks can ever be comprehensive, since it is always possible that characteristics in the data of an unexpected kind could be overlooked". Box/Jenkins (1976), S. 286.

des Erscheinungsbildes der geschätzten Autokorrelationen und partiellen Autokorrelationen gleich plausibel erscheinen, zu identifizieren. Die Ergebnisse der Schätzung und Diagnostic Checks sollten dann die Wahl eines Modells ermöglichen, das das Verhalten der beobachteten Zeitreihe am adäquatesten beschreibt.¹⁾

Auch die mehrmalige Anwendung der drei Phasen der Box/Jenkins-Strategie kann natürlich keine absolute Gewißheit über die Richtigkeit des gewählten Modells verschaffen. In die Box/Jenkins-Strategie fließt ein erhebliches Maß an subjektiver Beurteilung ein - etwa bei der Interpretation des Erscheinungsbildes des Autokorrelogramms -; dieses subjektive Element wird das abschließend gewählte Modell stets der Kritik offenhalten.²⁾

2. Die Autokorrelationen $r_{zz}(k)$ und $r_{\hat{u}\hat{u}}(k)$, die Kreuzkorrelationen $r_{\hat{u}z}(k)$ sowie die partiellen Autokorrelationen a_{kk} ³⁾ sind jeweils für die folgenden Lag-Bereiche ausgewiesen:

$$\begin{array}{ll} r_{zz}(k) & 1 \leq k \leq 24 \\ r_{\hat{u}\hat{u}}(k) & 1 \leq k \leq 24 \\ \underline{r_{\hat{u}z}(k)} & - 24 \leq k \leq 24 \end{array}$$

- 1) S. Box/Jenkins (1976), S. 177: "In employing the estimated autocorrelation function as a tool for identification, it is usually possible to be fairly sure about broad characteristics, but more subtle indications may or may not represent real effects, and two or more related models may need to be entertained and investigated further at the estimation and diagnostic checking stages of model building".
- 2) S. auch Granger/Newbold (1977), S. 72: "... there exists no surefire deterministic approach to the problem. Rather, it is necessary to exert a degree of judgement, the facility for which is greatly improved by experience".
- 3) Es wäre im Sinne der bisherigen Notation, die Autokorrelationen derjenigen sukzessiven Differenzen einer beobachteten Zeitreihe mit $r_{xx}(k)$ zu bezeichnen, die ein nichtstationäres Erscheinungsbild vermitteln. Hiervon ist jedoch abgesehen, weil sonst das Lesen der ausgewiesenen Autokorrelogramme unnötig kompliziert würde. Alle Autokorrelationen der Originalserien und der sukzessiven Differenzen sind daher mit $r_{zz}(k)$ benannt.

$$a_{kk} \quad 1 \leq k \leq 10$$

Da die Beobachtungen aller Variablen Quartalswerte sind, sollten die gewählten Lag-Bereiche als ausreichend angesehen werden können.

3. Als Standardfehler der Koeffizienten sind die folgenden Werte angesetzt:

	Standardfehler	
$r_{zz}(k)$	$T^{-1/2}$	$1 \leq k \leq 12$
	$T^{-1/2} (1 + 2 \sum_{v=1}^{12} r_{zz}^2(v))^{1/2}$	$13 \leq k \leq 24$
$r_{\hat{u}\hat{u}}(k)$	$T^{-1/2}$	$1 \leq k \leq 24$
$r_{\hat{u}z}(k)$	$T^{-1/2}$	$24 \leq k \leq 24$
a_{kk}	$T^{-1/2}$	$1 \leq k \leq 10$

Die ausgewiesenen Standardfehler sollten nur als grobe Maßstäbe der Signifikanz der Koeffizienten angesehen werden. Auf die Möglichkeit der Unterschätzung der Signifikanz der $r_{\hat{u}\hat{u}}(k)$ für kleine k bei Unterstellung einer Standardabweichung von $T^{-1/2}$ ist bereits oben hingewiesen worden.

424 Die Prognoseformel eines ARIMA- bzw. ARMA-Modells

Die folgenden Ausführungen beziehen sich auf einen ARIMA-Prozeß X_t . Sie gelten sinngemäß für einen ARMA-Prozeß Z_t .

Es wird unterstellt, in Periode t sei X_{t+1} zu prognostizieren. t ist also der Prognoseursprung und 1 die Prognosedistanz. Wenn die d sukzessiven Differenzen in das autoregressive Operatorpolynom integriert werden, d.h.

$$(4.58) \quad a^*(B) = a(B)(1 - B)^d$$

so gilt:¹⁾

$$(4.59) \quad X_{t+1} = a_1^* X_{t-1-1} + \dots + a_{p+d}^* X_{t+1-p-d} - b_1 U_{t-1-q} \\ - \dots - b_q U_{t+1-q} + U_{t+1}$$

Es sei:

$$(4.60) \quad (X_{t+1}) = E_t(X_{t+1}) = E(X_{t+1} | X_t, X_{t-1}, \dots) \\ (U_{t+1}) = E_t(U_{t+1}) = E(U_{t+1} | X_t, X_{t-1}, \dots) \\ \hat{X}_t(1) \quad \text{Minimale "Mean Square Error"-Prognose von} \\ X_{t+1} \text{ in Periode } t.$$

Dann gilt, wenn in (4.59) die in t unbekannten Werte durch ihre bedingten Erwartungswerte in (4.60) ersetzt werden:²⁾

$$(4.61) \quad (X_{t+1}) = \hat{X}_t(1) = a_1^* (X_{t+1-1}) + \dots + a_{p+d}^* (X_{t+1-p-d}) \\ - b_1 (U_{t+1-1}) - \dots - b_q (U_{t+1-q}) \\ + (U_{t+1})$$

Für die in (4.61) aufgeführten bedingten Erwartungswerte sind die folgenden Größen zu substituieren:³⁾

$$(X_{t-j}) = X_{t-j} \quad j \geq 0 \\ (X_{t+j}) = \hat{X}_t(j) \quad j \geq 1 \\ (U_{t-j}) = U_{t-j} \quad j \geq 0 \\ (U_{t+j}) = 0 \quad j \geq 1$$

Da im allgemeinen die X_{t-j} und U_{t-j} ($j \geq 0$) unbekannt sind, werden die jeweiligen Realisationen substituiert.

1) Vgl. zum folgenden Box/Jenkins (1976), S. 126 ff.

2) Vgl. ibid., S. 128.

3) Vgl. ibid., S. 130.

43 Aufteilung der Beobachtungen auf Sample- und Post-Sample-Periode

Bei der Aufteilung der Beobachtungen auf Sample- und Post-Sample-Periode im ersten Teil der empirischen Analyse ist der begrenzten Zahl der Beobachtungen Rechnung zu tragen. Das Survey Research Center führt in seinen Daten-Bändern den ICS quartalsweise seit 1954.1 auf. Da zum Zeitpunkt der Erstellung der Analyse Beobachtungen bis einschließlich 1976.3 vorlagen, kann von einer Gesamtzahl von 91 Beobachtungen des ICS ausgegangen werden. Um nicht zu große Sample-Varianzen durch die Wahl einer zu kleinen Sample-Periode zu erhalten, ist der Beginn der Post-Sample-Periode auf 1973.1 angesetzt. Die Post-Sample-Periode von 1973.1 - 1976.3 umfaßt damit einen Zeitraum, der von starken Schwankungen der Gebrauchsgüter- und Autoausgaben gekennzeichnet ist.¹⁾

Diese Aufteilung auf Sample- und Post-Sample-Periode beläßt 14 Beobachtungen für den Post-Sample-Test beim Mueller-Modell und 15 Beobachtungen beim Fair-Modell. Die unterschiedliche Fallzahl ist durch die Berechnungsform der jeweiligen abhängigen Variablen bedingt: da die abhängigen Variablen des Mueller-Modells als gleitende Halbjahreswerte auszuweisen sind, geht bei 91 Quartalswerten eine Beobachtung "verloren", so daß nur 90 Beobachtungen zur Verfügung stehen. Um den gleichzeitigen Beginn der Post-Sample-Periode für das Mueller- und das Fair-Modell zu gewährleisten, ist beim Mueller-Modell die Zahl der Beobachtungen in der Post-Sample-Periode um eine verringert worden.

44 Das Entscheidungskriterium der Prognosebewertung

Nach Granger/Newbold sollte eine Prognosebewertung auf ei-

1) Dies wird z.B. aus Zeichnung 2 deutlich. Vgl. S. 89.

ner subjektiven und objektiven Ebene stattfinden.¹⁾

1. Auf der subjektiven Ebene wird das Verhalten der Prognosen nach ihrem Erscheinungsbild beurteilt. Auffällige Abweichungen der Prognosen von den tatsächlichen Werten sollten hier ebenso wie das Versagen, Wendepunkte zu prognostizieren, aufgedeckt und interpretiert werden.²⁾ Die Grenzen der Analyse auf der subjektiven Ebene sind durch die Nichtverallgemeinerungsfähigkeit ihrer Resultate gegeben.

2. Die Frage der Verallgemeinerungsfähigkeit wird auf der objektiven Ebene zu beantworten gesucht. Unter der Vielzahl objektiver Kriterien eignet sich der durchschnittliche quadrierte Prognosefehler (MSE)³⁾ besonders gut zur Beurteilung der Prognosegüte verschiedene Modelle. Der MSE errechnet sich aus:⁴⁾

$$(4.62) \quad \text{MSE} = \frac{1}{T} \sum_{t=1}^T e_t^2$$

wobei

$$e_t = X_t - f_t$$

X_t Tatsächlicher Wert der zu prognostizierenden
Reihe in t ;

f_t Prognose des tatsächlichen Wertes in t .

Granger/Newbold nennen drei Gründe für die Eignung des MSE: er basiert auf einer quadratischen Verlustfunktion, die im allgemeinen als realitätsnahe gelten kann; er ist

1) Vgl. Granger/Newbold (1977), S. 279.

2) Vgl. *ibid.*

3) MSE = Mean squared error.

4) Vgl. Pindyck/Rubinfeld (1976), S. 316.

mathematisch einfacher zu behandeln als andere Maßgrößen; er steht in enger Beziehung zur Summe der kleinsten Quadrate, die bei der Schätzung eines Modells Berücksichtigung findet.¹⁾

3. Granger/Newbold²⁾ sowie Ashley/Granger/Schmalensee³⁾ empfehlen für den Signifikanztest des Unterschiedes der MSE zweier Modelle das folgende Verfahren.

Es seien X_t eine Zeitreihe und f_{1t} und f_{2t} ($t = 1, \dots, T$) Reihen von Prognosen, die in Periode $(t - 1)$ mithilfe zweier Modelle 1 und 2 für Prognosedistanz 1 erstellt sind. Die Prognosefehler e_{1t} und e_{2t} ergeben sich dann aus:

$$(4.63) \quad \begin{aligned} e_{1t} &= X_{1t} - f_{1t} \\ e_{2t} &= X_{2t} - f_{2t} \end{aligned}$$

Es sei ferner unterstellt, die Reihe (e_{1t}, e_{2t}) entstamme einer normal verteilten Grundgesamtheit, mit Mittelwert 0, Varianzen σ_1^2 und σ_2^2 und Korrelationskoeffizient r . Hierbei ist angenommen, die Reihen e_{1t} und e_{2t} seien nicht autokorreliert.

1) Vgl. Granger/Newbold (1977), S. 280. Zur Eignung des MSE vgl. auch Kashyap (1976), S. 24. S. auch Granger/Newbold (1973), S. 39: "... with the art in its present state it is extremely difficult to carry an analysis very far unless the least squares criterion is employed". Der MSE erfüllt darüberhinaus durch die Durchschnittsbildung über alle Prognosefehler die Anforderungen, die nach Mueller für die Beurteilung der Prognosegüte des ICS erfüllt sein müssen: "One way of judging the quality of time series prediction is accuracy at turning points in the dependent variable. Yet this test is too narrow, since a false signal between turning points may be as misleading as the absence of a correct signal prior to the turning point. The analysis which follows therefore is concerned with the predictive record of consumer attitudes over the entire ten-year time span, giving equal weight to all observations. It is to be determined how consistently attitude change foreshadows fluctuations in discretionary spending ...". Mueller (1963), S. 900.

2) Vgl. Granger/Newbold (1977), S. 280 f.

3) Vgl. Ashley/Granger/Schmalensee (1977), S. 8 f.

Es seien die Größen de_t und se_t definiert, wobei

$$(4.64) \quad \begin{aligned} de_t &= e_{1t} - e_{2t} \\ se_t &= e_{1t} - e_{2t} \end{aligned}$$

Unter den getroffenen Voraussetzungen gilt:

$$(4.65) \quad E(de_t se_t) = \sigma_1^2 - \sigma_2^2 = MSE_1 - MSE_2$$

wobei

$$MSE_i \quad \text{MSE der Prognosen von Modell } i \quad (i = 1, 2)$$

Gleichheit von MSE_1 und MSE_2 ist nur gegeben, wenn de_t und se_t unkorreliert sind. Es läßt sich daher ein Test auf die Korrelation zwischen de_t und se_t durchführen, der auf dem im Sample gemessenen Korrelationskoeffizient beruht. Signifikanz eines positiven (negativen) Korrelationskoeffizienten entspricht dann für die gewählte Irrtumswahrscheinlichkeit einem höheren MSE_1 (MSE_2).

Die Voraussetzung der Nichtautokorrelation der e_{it} ($i = 1, 2$) sowie die eines Null-Mittelwertes ist bei Ashley/Granger/Schmalensee aufgehoben. Sie schlagen eine Regression von de_t auf se_t vor, wobei einer möglicherweise existierenden Autokorrelation in der stochastischen Größe durch Verwendung eines geeigneten Schätzverfahrens (bei Ashley/Granger/Schmalensee: die Cochrane/Orcutt-Methode) Rechnung getragen wird. Eine signifikant positive (negative) Schätzung des Parameters von se_t weist dann für die gewählte Irrtumswahrscheinlichkeit auf einen positiven (negativen) Unterschied zwischen MSE_1 und MSE_2 hin.

4. Die folgende Prognose-Bewertung stützt sich der Anre-

gung Granger/Newbolds folgend auf den MSE, ohne damit jedoch die Nützlichkeit anderer Maßgrößen bestreiten zu wollen. Die Beschränkung auf den MSE richtet sich in erster Linie an der Zahl der Beobachtungen in der Post-Sample-Periode aus, die jeweils zu niedrig liegt, um von der Verwendung einer Vielzahl von Maßgrößen zusätzliche Aufschlüsse erhoffen zu lassen.

Daneben wird auch das Erscheinungsbild der Prognosen bzw. Prognosefehler selbst beurteilt - die Analyse auf der subjektiven Ebene von Granger/Newbold -, um zusätzliche Aufschlüsse über die Prognosegüte der Modelle zu gewinnen.

45 Die geschätzten Modelle und ihre Prognoseformeln

451 Schätzung des Mueller-Modells

1. Erwartungsgemäß liefert die OLS-Schätzung des Mueller-Modells - deren Ergebnisse in Tabelle 4 ausgewiesen sind - klare Hinweise auf die Autokorrelation der stochastischen Größe. Die DW-Statistik zeigt signifikante Autokorrelation in den Residuen beider Gleichungen auf.

Tabelle 4

Ergebnisse der OLS-Schätzung des Mueller-Modells

Sample-Periode: 1954.1 - 1972.4

Abhängige Variable	Schätzung für			$\bar{R}^2$	DW
	c_0	c_1	c_2		
$CDM_{t+1,t+2}$	- 635	.21	2.05	.91	.18
$CAM_{t+1,t+2}$	- 303	.08	1.70	.78	.28
Legende:					
$CDM_{t+1,t+2}$	Consumer durable goods expenditures in quarters (t + 1) and (t + 2) in constant dollars of 1972;				
$CAM_{t+1,t+2}$	Consumer expenditures on motor vehicles and parts in quarters (t + 1) and (t + 2) in constant dollars of 1972.				

Zur Bedeutung der Parameter s. Gleichung (4.1).

Die Geld-Variablen sind außer für Preisveränderungen auch für die Zahl der Familien sowie saisonal adjustiert.

2. Vor der Anwendung des Durbin-Verfahrens ist zu klären, welche Annahmen in bezug auf die autokorrelative Struktur der stochastischen Größe des Mueller-Modells zu treffen sind. Tabelle 5 weist die Autokorrelationen und partiellen Autokorrelationen der Residuen der OLS-Schätzung des Mueller-Modells für beide Ausgabekategorien aus. Die Autokorrelationen beginnen jeweils auf sehr hohem Niveau und sinken dann relativ zügig ab, um dann etwa von Lag $k = 5$ an im nichtsignifikanten Bereich zu bleiben. Gegen die Annahme eines Moving Average-Prozesses erster Ordnung spricht hier insbesondere, daß die Autokorrelationen für Lag $k = 2$ nicht abrupt auf null fallen. Ein autoregressiver Prozeß erster Ordnung könnte vorliegen, weil $r_{zz}(2)$ ungefähr dem Quadrat von $r_{zz}(1)$ entspricht (in beiden Autokorrelogrammen). Hingegen erscheinen $r_{zz}(3)$ und $r_{zz}(4)$ jeweils als etwas zu hoch, um einem geometrisch gedämpften Absinken der Autokorrelationen eines autoregressiven Prozesses erster Ordnung zu entsprechen. Die partiellen Autokorrelationen legen eher einen autoregressiven Prozeß zweiter Ordnung nahe. Es wird daher im weiteren unterstellt, das Bildungsgesetz der stochastischen Größe des Mueller-Modells sei für beide Ausgabekategorien in der Form eines autoregressiven Prozesses zweiter Ordnung gegeben:²⁾

$$(4.66) \quad (1 - a_1 B - a_2 B^2) U_{t+1,t+2} = E_{t+1,t+2}$$

$E_{t+1,t+2}$ sei weißes Rauschen.

3. Die Ergebnisse der Schätzung mithilfe des Durbin-Verfahrens sind in Tabelle 6 ausgewiesen. Ein Vergleich dieser Ergebnisse mit denen bei Mueller (1963) bestätigt die be-

- 1) Gegen einen Moving Average-Prozeß erster Ordnung spricht ferner, daß $r_{zz}(1)$ (in beiden Autokorrelogrammen) deutlich über der für einen solchen Prozeß maximal möglichen Größe von .50 liegt. Vgl. hierzu Box/Jenkins (1976), S. 69.
- 2) Zur Plausibilität der Annahme eines autoregressiven Prozesses zweiter Ordnung für die stochastische Größe vgl. Klein (1968), S. 52.

Tabelle 5

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) der Residuen der

OLS-Schätzung des Mueller-Modells

Sample-Periode: 1954.1 - 1972.4

1. Abhängige Variable: $CIM_{t+1,t+2}$

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{zz}(k)$		.82	.58	.37	.20	.11	.04	-.03	-.09	-.08	-.04	.00	.04	.12
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{zz}(k)$		.06	.07	.08	.05	-.02	-.09	-.16	-.15	-.16	-.17	-.19	-.16	.22
k	1	2	3	4	5	6	7	8	9	10				
a_{kk}		.82	-.27	-.05	-.03	.06	-.07	-.09	-.02	.16	.01			.12

2. Abhängige Variable: $CAM_{t+1,t+2}$

	k	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{zz}(k)$		.79	.52	.30	.12	.03	-.02	-.09	-.17	-.15	-.11	-.07	.00	.12
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{zz}(k)$		.02	.02	.02	-.02	-.08	-.11	-.16	-.16	-.14	-.15	-.17	-.16	.20
k	1	2	3	4	5	6	7	8	9	10				
a_{kk}		.79	-.28	-.02	.00	.08	-.04	-.15	-.08	.17	-.02			.12

Tabelle 6

Ergebnisse der Schätzung des Mueller-Modells mithilfe des Durbin-Verfahrens

(In Klammern: t-Statistik)¹⁾

Sample-Periode: 1954.1 - 1972.4

Abhängige Variable	Schätzung für						$\bar{R}^2$	DW	F(4,68)
	c_0	c_1	c_2	a_1	a_2				
CDM _{t+1,t+2}	- 628 (5.92)	.23 (12.56)	.79 (1.91)	1.32	-.45	.69	1.49	79	
CAM _{t+1,t+2}	- 284 (4.51)	.09 (10.32)	.91 (2.58)	1.16	-.39	.60	1.70	53	

Legende: s. Gleichung (2.11).

Zur Bedeutung der Parameter s. Gleichungen (4.1) und (4.66).

reits geäußerte Vermutung, daß die positive Einschätzung der Erklärungskraft des ICS durch Mueller im wesentlichen auf der fehlerhaften Interpretation der OLS-Schätzung beruht. Tatsächlich weisen die Ergebnisse des statistisch besser abgesicherten Durbin-Verfahrens auf einen Erklärungswert des ICS im Rahmen des Mueller-Modells hin, der für CDM_{t+1,t+2} als mäßig und für CAM_{t+1,t+2} als gerade befriedigend bezeichnet werden muß.

Die in Tabelle 6 ausgewiesenen Ergebnisse erlauben einige weitere Schlußfolgerungen. Zunächst fällt auf, daß die Hypothese $H_0: r_{ZZ}(k) = 0$ für die stochastische Größe $E_{t+1,t+2}$ der Gleichung für CAM_{t+1,t+2} aufgrund des Wertes der DW-Statistik nicht abgelehnt werden kann.²⁾ Im Falle der stochastischen Größe der Gleichung für CDM_{t+1,t+2} liegt die DW-Statistik in der Unbestimmtheits-Region (die kritischen Werte der d_1 - und d_u -Verteilung sind für beide Gleichungen

1) Die t-Statistik der autoregressiven Parameter a_1 und a_2 wird beim Durbin-Verfahren nicht ausgewiesen.

2) Die $r_{ZZ}(k)$ sind hier die Autokorrelationen von $E_{t+1,t+2}$

1.48 bzw. 1.60, Irrtumswahrscheinlichkeit .05). Insgesamt scheinen die Ergebnisse der mithilfe des Durbin-Verfahrens durchgeführten Schätzung somit im Vergleich zu denen der OLS-Schätzung in geringerem Umfang unter den Problemen der Autokorrelation der stochastischen Größe zu leiden.¹⁾

Der F-Test zeigt für beide Gleichungen, daß die Hypothese $H_0: c_1 = c_2 = 0$ abgelehnt werden muß, da der kritische Wert der F-Verteilung mit ca. 2.52 (4, 68 Freiheitsgrade) deutlich unterhalb der ausgewiesenen Werte der F-Statistik liegt (Irrtumswahrscheinlichkeit .05).

Die Vorzeichen des ICS-Parameters sind in beiden Gleichungen erwartungsgemäß positiv; einem Ansteigen des ICS, was eine Verbesserung des Konsumklimas anzeigen sollte, entspricht also im Rahmen des Mueller-Modells auch ein Ansteigen der diskretionären Konsumausgaben (et v.v.). Aus der Größe des geschätzten Parameters des ICS in den beiden Gleichungen sowie aus der ihrer jeweiligen t-Statistik könnte zudem ein Hinweis auf eine erhöhte Bedeutung des ICS zur Prognose von $CAM_{t+1,t+2}$ im Vergleich zu der von $CDM_{t+1,t+2}$ herausgelesen werden.

Die Noise-Modelle beider Gleichungen sind stationär, da die Wurzeln der Gleichungen

$$(4.67) \quad (1 - 1.32B + .45B^2) = 0$$

bzw.

$$(4.68) \quad (1 - 1.16B + .39B^2) = 0$$

jeweils außerhalb des Einheitskreises liegen.²⁾

1) Da aufgrund des Durbin-Verfahrens die verzögerte abhängige Variable implizit unter den unabhängigen Variablen aufgeführt ist, ist die DW-Statistik hier nur bedingt aussagefähig.

2) Die Vertrauensbereiche der Wurzeln sind nicht berechnet.

452 Identifikation und Schätzung des "naiven" Alternativmodells zum Mueller-Modell

4521 Identifikation

Zeichnung 2 beschreibt die Beobachtungen für $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ für die Sample- und Post-Sample-Periode. Die Identifikation des "naiven" Modells basiert allein auf der Sample-Periode, deren Ende durch eine gestrichelte Linie bezeichnet ist.¹⁾


1. Bereits das Erscheinungsbild des geglätteten Kurvenverlaufs läßt für beide Ausgabenkategorien die Existenz von Autokorrelation vermuten. Darüberhinaus scheint Nichtstationarität vorzuliegen, die sich hier in einem trendförmigen Anstieg der Beobachtungen im Zeitablauf bemerkbar macht. Für die Annahme der Autokorrelation bzw. Nichtstationarität lassen sich auch ohne detaillierte Analyse des Erzeugungsmechanismus' der Reihen Gründe aufzählen. Zum einen sorgt - wie bereits ausgeführt - die Definition von $CDM_{t+1,t+2}$ bzw. $CAM_{t+1,t+2}$ als gleitende halbjährliche Werte auch dann für Autokorrelation, wenn die zugrundeliegenden Quartalswerte jeweils als Realisation von weißem Rauschen anzusehen wären. Ferner dürfte sich in den Gebrauchsgüter- bzw. Autoausgaben das positive Realwachstum der US-Wirtschaft in der Sample-Periode widerspiegeln.

2. Die Tabellen 7 und 8 geben die Autokorrelationen und partiellen Autokorrelationen für $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ wieder.

Das Erscheinungsbild der Autokorrelationen der nicht diffe-

1) In Zeichnung 2 mußte aus graphischen Gründen als Einheit für $CDM_{t+1,t+2}$ bzw. $CAM_{t+1,t+2}$ 1000 US-Dollar gewählt werden.

Zeichnung 2

Sample- und Post-Sample-Beobachtungen von $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ 

Legende:

 $CDM = CDM_{t+1,t+2}$ $CAM = CAM_{t+1,t+2}$ $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ Consumer durable goods expenditures in quarters $(t+1)$ and $(t+2)$ in thousands of constant dollars of 1972;Consumer expenditures on motor vehicles and parts in quarters $(t+1)$ and $(t+2)$ in thousands of constant dollars of 1972. $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ sind für die Zahl der Familien sowie saisonal adjustiert.

Tabelle 7

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürCIDM
 $t+1, t+2$

Sample-Periode: 1954.1 - 1972.4

Differenzen-
filter

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.95	.89	.83	.79	.75	.74	.72	.70	.67	.64	.60	.56	.12
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.52	.47	.42	.37	.31	.26	.21	.17	.13	.09	.05	.01	.43
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.56	.16	.06	-.17	-.18	-.09	-.13	-.14	-.04	-.01	.00	.09	.12
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.06	.08	.19	.05	-.08	-.10	-.18	-.12	-.02	-.11	-.13	-.02	.16
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.95	-.09	.02	.05	.07	.15	.01	-.09	.01	-.03			.12
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.56	-.22	.11	-.36	.20	-.15	.01	-.16	.16	-.13			.12

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürCAN
(1,1,1,2)

Sample-Periode: 1954.1 - 1972.4

Differenzen-
filter

Differenzen- filter														Standard- fehler
$(1 - B)^0$	k	1	2	3	4	5	6	7	8	9	10	11	12	.12
	$r_{zz}(k)$	.92	.80	.70	.62	.58	.58	.60	.59	.58	.56	.54	.52	
	k	13	14	15	16	17	18	19	20	21	22	23	24	
$(1 - B)^1$	k	1	2	3	4	5	6	7	8	9	10	11	12	.15
	$r_{zz}(k)$	.48	.44	.39	.32	.25	.20	.15	.12	.09	.06	.03	.01	
	k	13	14	15	16	17	18	19	20	21	22	23	24	
$(1 - B)^0$	k	1	2	3	4	5	6	7	8	9	10	11	12	.12
	$r_{zz}(k)$	.44	.00	-.05	-.28	-.21	-.06	-.13	-.12	.00	-.07	-.05	.12	
	k	13	14	15	16	17	18	19	20	21	22	23	24	
$(1 - B)^1$	k	1	2	3	4	5	6	7	8	9	10	11	12	.15
	$r_{zz}(k)$	.04	.06	.19	-.01	-.09	-.05	-.11	.00	.05	-.11	-.11	.04	
	k	13	14	15	16	17	18	19	20	21	22	23	24	
$(1 - B)^0$	k	1	2	3	4	5	6	7	8	9	10	11	12	.12
	a_{kk}	.92	-.23	.04	.05	.15	.24	.00	-.07	.12	.00			
	k	13	14	15	16	17	18	19	20	21	22	23	24	
$(1 - B)^1$	k	1	2	3	4	5	6	7	8	9	10	11	12	.12
	a_{kk}	.44	-.25	.08	-.38	.17	-.17	-.05	-.16	.10	-.25			
	k	13	14	15	16	17	18	19	20	21	22	23	24	

renzierten Reihen beschreibt erwartungsgemäß nichtstationäres Verhalten. Die $r_{zz}(k)$ starten auf sehr hohem Niveau und sinken nur sehr zögernd gegen null ab. Einmaliges Differenzieren genügt jedoch offensichtlich bei beiden Reihen, um Stationarität zu erzeugen. Beide Autokorrelogramme besitzen nur für Lag $k = 1$ relativ hohe Werte; mit $k = 2$ sinken die Autokorrelationen jedoch stark ab und gehorchen im weiteren Verlauf stationären Gesetzmäßigkeiten. Weiteres Differenzieren ist somit unnötig.

Die Autokorrelationen der ersten Differenzen der Reihen besitzen erkennbar noch zu viel Struktur, um eine Realisation von weißem Rauschen zu beschreiben. Der Vergleich mit dem Standardfehler von .12 zeigt für $r_{zz}(1)$ jeweils signifikante Werte; darüberhinaus ist das Verhalten der Autokorrelationen für den gesamten berücksichtigten Lagbereich auffallend von einer langgestreckten Schwingung mit negativen Gipfeln um Lags $k = 4, 5, 19$ und positiven Gipfeln um Lag $k = 16$ bestimmt. Auch die partiellen Autokorrelationen weisen auf noch existente Autokorrelation in den ersten Differenzen von $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ hin.

3. Verschiedene ARIMA-Modelle bieten sich aufgrund der Autokorrelationen und partiellen Autokorrelationen der ersten Differenzen der Ausgabenkategorien an.

Ein ARIMA-Modell der Ordnung (0,1,1) könnte vorliegen, wenn die Abweichungen der Autokorrelationen der ersten Differenzen für $k > 1$ lediglich als Sample-Variation um einen Mittelwert von null zu interpretieren wären. Da die Autokorrelationen eines Moving Average-Prozesses der Ordnung q null sind für $k > q$, könnte die Entscheidung für dieses Modell vertreten werden.

Die auffälligen Gipfel der Autokorrelationen der ersten Differenzen könnten jedoch auch als Hinweis auf die Existenz einer saisonalen Komponente aufgefaßt werden. Das Auftreten einer saisonalen Komponente in den saisonal adjustierten Serien $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ bzw. ihren ersten Differenzen könnte auf die zur Adjustierung verwendete Methode zurückzuführen sein, die offensichtlich nicht nur die für ökonomische Reihen typische positive saisonale Autokorrelation (bei Quartalswerten regelmäßig mit saisonaler Spanne 4) beseitigt, sondern sogar eine leicht negative Autokorrelation induziert.¹⁾ Falls dieser Effekt ein zeitinvariantes Kennzeichen des Adjustierungs-Verfahrens ist, erscheint es erwägenswert, ihm bei der Identifikation eines ARIMA-Modells Rechnung zu tragen.

In diesem Fall bietet sich die Identifikation eines saisonalen ARIMA-Modells der Form

$$(4.69) \quad (1 - a_{1,4}B^4)(1 - B)X_t = (1 - b_1B)U_t$$

oder

$$(4.70) \quad (1 - B)X_t = (1 - b_1B)(1 - b_{1,4}B^4)U_t$$

an, wobei $a_{1,4}$ bzw. $b_{1,4}$ saisonale autoregressive bzw. Moving Average-Parameter sind.

Die theoretischen Autokorrelationen des ersten saisonalen Modells besitzen für die ersten Differenzen das folgende Aussehen:²⁾

1) Vgl. hierzu Nelson (1973), S. 205.

2) Zu den Autokorrelationen saisonaler ARIMA-Modelle vgl. Box/Jenkins (1976), S. 329 ff., Granger/Newbold (1977), S. 95 ff.

$$(4.71) \quad r_{ZZ}(k) \neq 0 \quad k = 1$$

Für $k > 1$ folgen die $r_{ZZ}(k)$ der Differenzengleichung:

$$(4.72) \quad (1 - a_{1,4} B^4) r_{ZZ}(k) = 0$$

(B operiert an k)

Insbesondere gilt:

$$(4.73) \quad r_{ZZ}(4k - 1) = r_{ZZ}(4k + 1)$$

d.h. um $r_{ZZ}(k)$ befinden sich jeweils symmetrische Gipfel.

Dieses saisonale Modell addiert zu dem oben vorgestellten ARIMA-Modell der Ordnung (0,1,1) eine saisonale autoregressive Komponente, die die Gipfel der Autokorrelationen der ersten Differenzen für Lags $k = 4, 8$ erklären könnte. Die für dieses Modell typische Symmetrie der den Gipfeln unmittelbar benachbarten $r_{ZZ}(k)$ ist bei den $r_{ZZ}(k)$ allerdings nicht einwandfrei festzustellen; Modell-Inadäquanz oder Sample-Variation können hierfür verantwortlich sein.

Die Autokorrelationen der ersten Differenzen des zweiten saisonalen Modells gehorchen dem Bildungsgesetz:

$$(4.74) \quad r_{ZZ}(k) \neq 0 \quad k = 1, 3, 4, 5$$

$$(4.75) \quad r_{ZZ}(k) = 0 \quad k = 2 \\ k > 5$$

Schließlich könnte $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ auch ein ARIMA-Modell der Ordnung (1,1,1) zugrundeliegen, dessen erste Differenzen die folgende autokorrelative Struktur besitzen:

$$(4.76) \quad r_{ZZ}(k) \neq 0 \quad k = 1 \text{ (falls } a_1 \neq b_1 \text{)}$$

$$(4.77) \quad (1 - a_1 B)r_{ZZ}(k) = 0 \quad k > 1$$

(B operiert an k)

Für $k > 1$ verhalten sich die Autokorrelationen der ersten Differenzen eines ARIMA-Modells der Ordnung (1,1,1) also wie die der ersten Differenzen eines ARIMA-Modells der Ordnung (1,1,0), d.h. geometrisch gedämpft (für $a_1 > 0$) oder oszillierend geometrisch gedämpft (für $a_1 < 0$). Dieses Modell könnte insbesondere zur Erklärung des Verhaltens der Autokorrelationen der ersten Differenzen von $CDM_{t+1,t+2}$ für Lags $k = 1, 2, 3$ herangezogen werden.

4522 Schätzung und Diagnostic Checks

Als bestes Modell aufgrund der Ergebnisse der Schätzung und der Diagnostic Checks hat sich für $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ das in Gleichung (4.70) vorgestellte saisonale ARIMA-Modell erwiesen.^{1), 2)} Tabelle 9 zeigt die geschätzten Parameter

- 1) Jedes Modell ist mit einer Konstante geschätzt; falls die Konstante für Irrtumswahrscheinlichkeit .05 nicht signifikant war, wurde das Modell neu - ohne Konstante - geschätzt.
- 2) Die Schätzung der anderen in der Identifikations-Phase überprüften Modelle erbrachte die folgenden Ergebnisse:

(In Klammern: t-Statistik)

1. $CDM_{t+1,t+2}$

$$(1 - B)X_t = (1 + .98B)U_t + .01$$

(89.96) (2.29)

$$(1 + .25B^4)(1 - B)X_t = (1 + .96B)U_t + .01$$

(2.05) (26.40) (2.10)

$$(1 - .11B)(1 - B)X_t = (1 + .96B)U_t$$

(.97) (72.02)

2. $CAM_{t+1,t+2}$

$$(1 - B)X_t = (1 + .99B)U_t + .01$$

(69.14) (2.00)

Tabelle 9

Ergebnisse der Schätzung des univariaten ARIMA-Modells
für CDM_{t-1,t+2} und CAM_{t-1,t+2}

(In Klammern: t-Statistik)

Sample-Periode: 1954.1 - 1972.4

Geschätztes ARIMA-Modell

Q $x_{.05,22}^2$ $x_{.10,22}^2$

1. CDM_{t-1,t+2}

$$(1 - B)X_t = (1 + .94B)(1 - .31B^4)U_t \quad 13.6 \quad 33.9 \quad 30.8$$

(43.38) (2.51)

2. CAM_{t-1,t+2}

$$(1 - B)X_t = (1 + .93B)(1 - .40B^4)U_t \quad 15.9 \quad 33.9 \quad 30.8$$

(29.08) (3.19)

Legende: s. Tabelle 13.

$$(1 + .30B^4)(1 - B)X_t = (1 + .95B)U_t$$

(2.58) (24.54)

$$(1 + .11B)(1 - B)X_t = (1 + .97B)U_t$$

(.91) (89.64)

Das ARIMA-Modell der Ordnung (0,1,1) ist für beide Ausgabekategorien nahezu nicht invertibel: dies könnte sich bei der Erstellung von Prognosen nachteilig bemerkbar machen. Das in Gleichung (4.69) vorgestellte saisonale ARIMA-Modell ist dem in (4.70) offensichtlich sehr ähnlich, wie am Beispiel von CAM_{t+1,t+2} leicht nachweisbar ist. Es gilt nämlich:

$$(1 + .95B)(1 + .30B^4)^{-1} = (1 + .95B)(1 - .30B^4 + .09B^8 - .03B^{12} + \dots)$$

Der Vergleich mit dem gewählten Modell läßt hier tatsächlich wenig Unterschiede erkennen, wenn die schnell absinkenden Werte der saisonalen Parameter für B^4 , B^8 , ... in betracht gezogen werden. Da das in Gleichung (4.69) vorgestellte ARIMA-Modell aufgrund der Schätzung für CDM_{t-1,t+2} eine Konstante, und damit einen Parameter mehr aufweist, ist die Entscheidung für das Modell (4.70) getroffen worden. Es erschien wünschenswert, für beide Ausgabekategorien ein ARIMA-Modell gleicher Ordnung zu verwenden.

Das ARIMA-Modell der Ordnung (1,1,1) ist wegen der Nichtsignifikanz des autoregressiven Parameters - für beide Ausgabekategorien - ungeeignet.

zusammen mit der jeweiligen Q-Statistik und den kritischen Werten der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeiten .05 und .10 (22 Freiheitsgrade).

Die für die Diagnostic Checks wichtigen Autokorrelationen $r_{\hat{u}\hat{u}}(k)$ und die Kreuzkorrelationen $r_{\hat{u}\hat{z}}(k)$ sind in den Tabellen 10 (für $CDM_{t+1,t+2}$) und 11 (für $CAM_{t+1,t+2}$) ausgewiesen. Die $r_{\hat{u}\hat{u}}(k)$ liegen in beiden Tabellen jeweils nahe bei null. Der reguläre Moving Average-Parameter hat die ursprünglich hohe Autokorrelation für Lag $k = 1$ der ersten Differenzen beseitigt, und der saisonale Moving Average-Parameter scheint die negativen Gipfel um Lags $k = 4, 5$ der Autokorrelationen der ersten Differenzen ebenfalls gut zu erfassen. Die Q-Statistik liegt für die Residuen beider Modelle unterhalb der kritischen Werte der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeit .10 (22 Freiheitsgrade). Die Kreuzkorrelationen $r_{\hat{u}\hat{z}}(k)$ geben für $k > 0$ für $CAM_{t+1,t+2}$ keinen Anlaß zu der Annahme, die differenzierte Serie und die zukünftige stochastische Größe seien miteinander korreliert. Für $CDM_{t+1,t+2}$ stören die drei positiven $r_{\hat{u}\hat{z}}(k)$ für $0 < k \leq 3$ etwas das ansonsten befriedigende Erscheinungsbild; dieser Effekt ist durch nicht vollständig ausräumbare Autokorrelation der differenzierten Serie für Lag $k = 2$ bedingt. Der Einbau eines zusätzlichen Parameters in das gewählte ARIMA-Modell ist wegen der Geringfügigkeit der $r_{\hat{u}\hat{z}}(k)$ ($0 < k \leq 3$) allerdings nicht nötig.

453 Schätzung des Fair-Modells

1. Die Schätzung des Fair-Modells erbringt für die beiden abhängigen Variablen CDF_t und CAF_t die in Tabelle 12 ausgewiesenen Ergebnisse. Beide Gleichungen sind mithilfe des von Fair empfohlenen Verfahrens geschätzt, d.h. es ist der

Tabelle 10

Autokorrelationen ($r_{\hat{u}\hat{u}}(k)$) und Kreuzkorrelationen ($r_{\hat{u}\hat{z}}(k)$) des univariaten ARIMA-Modells fürCINM
 $t+1, t+2$

Sample-Periode: 1954.1 - 1972.4

													Standard- fehler
	k	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}\hat{u}}(k)$		.08	.11	.15	.02	-.03	.00	-.07	-.08	.00	.01	-.01	.07
k		13	14	15	16	17	18	19	20	21	22	23	24
$r_{\hat{u}\hat{u}}(k)$		.05	-.07	.20	-.03	-.06	-.02	-.19	-.04	-.02	-.06	-.18	.06
k		0	1	2	3	4	5	6	7	8	9	10	11
$r_{\hat{u}\hat{z}}(k)$		.74	.13	.18	.14	.01	-.02	-.05	-.11	-.08	.01	-.03	.00
k		13	14	15	16	17	18	19	20	21	22	23	24
$r_{\hat{u}\hat{z}}(k)$		.00	.12	.17	-.04	-.04	-.09	-.13	-.03	-.04	-.17	-.08	.00
k		-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12
$r_{\hat{u}\hat{z}}(k)$		.66	.07	.13	-.10	-.21	-.07	-.07	-.11	-.05	.01	.00	.07
k		-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24
$r_{\hat{u}\hat{z}}(k)$		.08	-.03	.09	.09	-.08	-.05	-.15	-.16	-.02	-.03	-.13	-.04

Tabelle 11

Autokorrelationen ($r_{\hat{Q}\hat{Q}}(k)$) und Kreuzkorrelationen ($r_{\hat{Q}\hat{Z}}(k)$) des univariaten ARIMA-Modells fürCAM_{1+1, 1+2}

Sample-Periode: 1954.1 - 1972.4

														Standard fehler
k	1	2	3	4	5	6	7	8	9	10	11	12		
$r_{\hat{Q}\hat{Q}}(k)$	-.09	-.04	.05	.02	-.02	-.06	-.08	-.09	.08	-.09	-.05	.12	.12	
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{Q}\hat{Q}}(k)$	.01	-.09	.19	-.05	-.05	.02	-.17	.09	-.01	-.04	-.21	.16	.12	
k	0	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{Q}\hat{Z}}(k)$	.67	-.07	.04	.09	.01	-.05	-.06	-.13	-.05	.01	-.13	-.01	.12	
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{Q}\hat{Z}}(k)$	-.05	.10	.13	-.09	-.01	-.04	-.05	.04	-.01	-.17	-.03	.07	.12	
k	-1	-2	-3	-4	-5	-6	-7 _A	-8	-9	-10	-11	-12		
$r_{\hat{Q}\hat{Z}}(k)$	.58	-.09	.05	-.20	-.24	-.04	-.07	-.11	.01	.00	-.08	.09	.12	
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{Q}\hat{Z}}(k)$	.08	-.06	.11	.07	-.10	.00	-.14	-.07	.09	-.02	-.14	.00	.12	

Tabelle 12

Ergebnisse der Schätzung des Fair-Modells(In Klammern: t-Statistik)¹⁾

Sample-Periode: 1954.1 - 1972.4

Abhängige Variable	c_0	c_1	c_2	c_3	a_{11}	$\bar{R}^2$	DW	F(4,68)
CDF_t	- 3.981 (2.96)	.099 (35.39)	.015 (2.03)	.009 (1.42)	.72	.99	2.20	4718
CAF_t	- 4.945 (3.98)	.045 (30.16)	.031 (3.41)	.012 (2.10)	.43	.98	2.02	1006

Legende:

CDF_t Consumer durable goods expenditures in quarter t in billions of current dollars;
 CAF_t Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars.
 CDF_t und CAF_t sind saisonal adjustiert.

Zur Bedeutung der Parameter s. Gleichungen (4.7) und (4.9).

Simultaneität zwischen CDF_t bzw. CAF_t und GNP_t sowie der Autokorrelation erster Ordnung in der stochastischen Größe Rechnung getragen.

2. Die Ergebnisse der Schätzung der Gleichung für CDF_t entsprechen - unter Berücksichtigung der unterschiedlichen Skalierung der in Geldeinheiten gemessenen Variablen - denen bei Fair; dies gilt im besonderen für die positiven Vorzeichen der beiden Lags des ICS sowie die t-Statistik der geschätzten Parameter. Der F-Test weist auch hier auf einen signifikanten Erklärungswert des Fair-Modells für beide Ausgabekategorien hin. Die Residuen scheinen in beiden Gleichungen zumindestens für Lag $k = 1$ keine nennenswerte Autokorrelation zu besitzen.²⁾

Wie schon bei der Schätzung des Mueller-Modells ist auf di jeweils recht niedrigen Werte der t-Statistik der beiden

- 1) Die t-Statistik des autoregressiven Parameters a_1 wird bei dem von Fair verwendeten Verfahren nicht ausgewiesen.
- 2) Die DW-Statistik ist hier nur bedingt aussagefähig, da die verzögerte abhängige Variable unter den Instrument-Variablen aufgeführt ist.

Lags des ICS hinzuweisen, die jedenfalls nicht auf eine überragende Bedeutung des ICS für die Prognose von Gebrauchsgüterausgaben - im Rahmen des Fair-Modells - schließen lassen. Immerhin befinden sich jedoch die positiven Vorzeichen des ICS in Einklang mit der Theorie der "Psychological Economics", nach der ein gleichgerichtetes Verhalten diskretionärer Konsumausgaben und des Konsumklimas zu erwarten ist.

Gemessen an der jeweiligen t-Statistik scheint der ICS eine größere Bedeutung für die Prognose von CAF_t als für die von CDF_t zu besitzen.


454 Identifikation und Schätzung des "naiven" Alternativmodells zum Fair-Modell und des univariaten Modells für FEX_t

4541 Identifikation

Zeichnung 3 ermöglicht eine erste Beurteilung der Zeitreihennatur von CDF_t und CAF_t . Der Identifikation liegt wiederum die Sample-Periode von 1954.1 - 1972.4 zugrunde, die in Zeichnung 3 durch eine gestrichelte Linie von der Post-Sample-Periode getrennt ist.

1. Beiden Reihen ist offensichtlich ein hohes Maß an Autokorrelation gemein; der trendähnliche Verlauf läßt sogar Nichtstationarität vermuten. Wie bereits oben ausgeführt, kann als Ursache für das nichtstationäre Erscheinungsbild das positive Realwachstum der US-Wirtschaft während der Sample-Periode angeführt werden. Zusätzliche nichtstationäre Impulse gehen von der Verwendung nicht preisbereinigter Werte aus.

2. Die Tabellen 13, 14 und 15 weisen die Autokorrelationen



Legende

$CDF_t = CDF_t$

Consumer durable goods expenditures in quarter t in billions of current dollars;

$CAF_t = CAF_t$

Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars.

CDF_t und CAF_t sind saisonal adjustiert.

und partiellen Autokorrelationen für sukzessive Differenzen von CDF_t , CAF_t und FEX_t aus.

Für $(1 - B)^0$ zeigen die Beobachtungen aller Reihen deutlich nichtstationäres Verhalten, denn das Autokorrelogramm startet jeweils auf hohem Niveau und sinkt nur sehr verzögert gegen null ab. Einmaliges Differenzieren ist demnach angezeigt, und für jede der drei Reihen wird hierdurch ein Autokorrelogramm erzeugt, das dem der Realisation eines stationären Prozesses entspricht. Die Autokorrelationen beginnen jeweils auf mittlerem oder niedrigem Niveau und sinken mit ansteigenden Lags schnell ab. Weiteres Differenzieren ist somit unnötig.

3. Die Autokorrelationen der ersten Differenzen von CDF_t und CAF_t besitzen wenig Struktur. Es existieren mehrere kleine Gipfel, die jedoch nicht dem Eindruck widersprechen, die differenzierten Reihen seien Realisationen von weißem Rauschen. Für $(1 - B)CAF_t$ könnte als Alternative ein Moving Average-Modell erster Ordnung, dessen Autokorrelationen null sind für Lags $k > 1$ oder, mit erheblichen Zweifeln, ein autoregressives Modell erster Ordnung mit einem negativen Parameter, der für ein oszillierend geometrisches Absinken der Autokorrelationen sorgt, identifiziert werden. Für $(1 - B)CDF_t$ ließe sich vielleicht ein Moving Average-Modell dritter Ordnung identifizieren, dessen erste beiden Parameter null sind. Dies könnte den vereinzelt kleinen Gipfel für Lag $k = 3$ erklären.

Es bleibt jedoch festzuhalten, daß das Erscheinungsbild der Autokorrelationen der ersten Differenzen von CDF_t und CAF_t keine deutlichen Hinweise auf Gesetzmäßigkeiten gibt und

Tabelle 13

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürC)DF
t

Sample-Periode: 1954.1 - 1972.4

Differenzen- filter	k												Standard- fehler
		1	2	3	4	5	6	7	8	9	10	11	12
(1 - B) ⁰	$r_{zz}(k)$	.95	.91	.86	.82	.78	.75	.73	.70	.67	.64	.62	.59
	k	13	14	15	16	17	18	19	20	21	22	23	24
	$r_{zz}(k)$	.55	.52	.48	.44	.41	.37	.34	.31	.28	.25	.22	.19
	$r_{zz}(k)$	.01	.14	.20	-.04	-.01	.07	.00	-.10	.00	.07	-.04	.17
(1 - B) ¹	k	13	14	15	16	17	18	19	20	21	22	23	24
	$r_{zz}(k)$	.05	.01	.25	.02	-.01	.11	-.10	.01	.04	.00	-.16	.15
	k	1	2	3	4	5	6	7	8	9	10		
	a_{kk}	.95	-.03	-.02	.05	.02	.06	.02	.03	-.11	.04		.11
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10		
	a_{kk}	.01	.14	.20	-.06	-.07	.05	.04	-.12	-.04	.12		.12

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für

CAF

Sample-Periode: 1954,1 - 1972,4

Differenzen-
filter

Differenzen- filter	CAF	k	t												Standard- fehler
			1	2	3	4	5	6	7	8	9	10	11	12	
(1 - B) ⁰	$r_{zz}(k)$	k	.93	.87	.80	.76	.72	.69	.67	.66	.64	.62	.61	.60	.11
		13	14	15	16	17	18	19	20	21	22	23	24		
	$r_{zz}(k)$	k	.57	.53	.49	.45	.41	.37	.33	.29	.26	.22	.20	.19	
(1 - B) ¹	$r_{zz}(k)$	k	.20	.04	.11	-.14	-.05	.04	.00	-.14	.05	-.01	-.11	.21	.12
		13	14	15	16	17	18	19	20	21	22	23	24		
	$r_{zz}(k)$	k	-.04	-.03	.23	-.08	-.05	.09	-.14	.06	.01	.01	-.19	.23	
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10				.11
	a_{kk}		.93	-.02	-.04	.10	.03	.12	.03	.08	-.11	.10			
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10				.12
	a_{kk}		-.20	.00	.12	-.10	-.11	.01	.04	-.14	-.04	.01			

Tabelle 15

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für

FEX

Sample-Periode: 1954.1 - 1972.4

Differenzen-
filter

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$(1 - B)^0$														
$r_{zz}(k)$	k	.97	.94	.91	.87	.83	.79	.75	.71	.67	.63	.59	.55	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.51	.47	.43	.39	.35	.31	.27	.23	.18	.14	.10	.05	.44
$(1 - B)^1$														
$r_{zz}(k)$	k	.32	.25	.19	.14	.17	-.02	.00	-.13	-.09	-.19	-.24	-.20	.12
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	-.11	-.09	-.08	-.02	-.01	.08	.06	.22	.13	.13	.16	-.02	.15
$(1 - B)^0$														
a_{kk}	k	.97	-.09	-.14	-.08	.07	-.05	-.01	-.07	.00	.01			.11
$(1 - B)^1$														
a_{kk}	k	.32	.17	.08	.04	.08	-.15	-.02	-.15	-.02	-.14			.12

ein Random Walk-Modell für CDF_t und CAF_t das naheliegendste Ergebnis ist. Die partiellen Autokorrelationen unterstützen diesen Eindruck.

4. Die Autokorrelationen der ersten Differenzen von FEX_t sinken, auf mittlerem Niveau beginnend, schnell in nichtsignifikante Bereiche ab. Das gesamte Erscheinungsbild des Autokorrelogramms ist von einer langgestreckten Schwingung bestimmt, aber es muß offen bleiben, ob dies auf Gesetzmäßigkeiten des zugrundeliegenden stochastischen Prozesses oder auf die statistischen Eigenschaften der $r_{zz}(k)$ - ihre möglicherweise beträchtlichen Kovarianzen - zurückzuführen ist.

Das nicht abrupte Absinken der Autokorrelationen der ersten Differenzen nach Lag $k = 1$ macht ein Moving Average-Modell erster Ordnung unwahrscheinlich; ein autoregressives Modell erster oder zweiter Ordnung könnte hingegen besser geeignet sein, zur Erklärung des Verhaltens der $r_{zz}(k)$ beizutragen. Für ein autoregressives Modell erster Ordnung spricht das Absinken der Autokorrelationen für niedrige Lags, das als Hinweis auf ein geometrisch gedämpftes Verhalten der theoretischen Autokorrelationen aufgefaßt werden könnte. Ein autoregressives Modell zweiter Ordnung, dessen charakteristische Gleichung konjugiert komplexe Wurzeln besitzt, würde das schwingungsähnliche Verhalten der Autokorrelationen verständlich machen, denn die theoretischen Autokorrelationen des zugrundeliegenden Prozesses weisen hier gedämpft sinusförmige Schwingungen auf.

4542 Schätzung und Diagnostic Checks

Als bestes Modell aufgrund der Ergebnisse der Schätzung

und der Diagnostic Checks haben sich für CDF_t und CAF_t jeweils Random Walk-Modelle und für FEX_t ein ARIMA-Modell der Ordnung (2,1,0) erwiesen.¹⁾

In Tabelle 16 sind die für CDF_t , CAF_t und FEX_t geschätzten ARIMA-Modelle aufgeführt, zusammen mit der Q-Statistik und den kritischen Werten der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeiten .05 und .10. Tabelle 17 zeigt die Autokorrelationen $r_{\hat{u}\hat{u}}(k)$ und Kreuzkorrelationen $r_{\hat{u}\hat{z}}(k)$ des ARIMA-Modells für FEX_t , die für die Prüfung der Adäquanz des identifizierten und geschätzten Modells von Bedeutung sind. Die entsprechenden Autokorrelationen und Kreuzkorrelationen müssen für das ARIMA-Modell für CDF_t bzw. CAF_t nicht ausgewiesen werden, da sie den Autokorrelationen $r_{zz}(k)$ der jeweiligen ersten Differenzen entsprechen.

Die Q-Statistik in Tabelle 16 liegt für jedes ARIMA-Modell unterhalb des kritischen Wertes der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeit .10, was als Hinweis auf die Adäquanz der Modelle aufzufassen ist. Auch die Kreuzkorrelationen $r_{\hat{u}\hat{z}}(k)$ in Tabelle 17 deuten nicht auf Mängel des für FEX_t identifizierten und geschätzten Modells.

- 1) Die Schätzungen anderer, nicht übernommener Modelle erbrachten die folgenden Ergebnisse:
(In Klammern: t-Statistik)

1. CDF_t

$$(1 - B)X_t = (1 + .19B^3)U_t + .29$$

(1.64) (3.90)

2. CAF_t

$$(1 + .20B)(1 - B)X_t = U_t + .16$$

(1.76) (2.76)

$$(1 - B)X_t = (1 - .19B)U_t + .14$$

(1.62) (2.90)

3. FEX_t

$$(1 - .37B)(1 - B)X_t = U_t + .10$$

(3.67) (1.79)

Die Nichtsignifikanz von Parameterschätzungen verhindert jeweils die Übernahme der Modelle.

Tabelle 16

Ergebnisse der Schätzung des univariaten ARIMA-Modells
für CDF_t , CAF_t und FEX_t

(In Klammern: t-Statistik)

Sample-Periode: 1954.1 - 1972.4

Geschätztes ARIMA-Modell	Q	$\chi^2_{.05,df}$	$\chi^2_{.10,df}$
1. CDF_t			
$(1 - B)X_t = U_t + .29$ (4.51)	18.9	35.2	32.0
2. CAF_t			
$(1 - B)X_t = U_t + .16$ (3.79)	25.9	35.2	32.0
3. FEX_t			
$(1 - .30B - .22B^2)(1 - B) = U_t$ (2.71) (1.97)	13.6	33.9	30.8

Legende:

CDF_t , CAF_t	s. Gleichung (4.7);
FEX_t	s. Abschnitt 412;
df	Zahl der Freiheitsgrade. ¹⁾

456 Die Prognoseformeln aller Modelle

4561 Die Prognoseformeln des Mueller-Modells und des
"naiven" Alternativmodells

1. Wie in Abschnitt 22 ausgeführt, sollte das in der Sample-Periode geschätzte Noise-Modell eines linearen Regressions-

1) Die Zahl der Freiheitsgrade ist für die einzelnen ARIMA-Modelle 23 (CDF_t und CAF_t) und 22 (für FEX_t). Das Random Walk-Modell für CDF_t bzw. CAF_t verbraucht einen Freiheitsgrad für die Schätzung der Konstanten.

Tabelle 17

Autokorrelationen ($r_{\hat{u}\hat{u}}(k)$) und Kreuzkorrelationen ($r_{\hat{u}\hat{z}}(k)$) des univariaten ARJMA-Modells für FLEX_t

Sample-Periode: 1954.1 - 1972.4

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{u}}(k)$		-.07	-.09	.02	.02	.15	-.09	.03	-.10	.02	-.06	-.16	-.12	.12
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{u}}(k)$		.01	-.02	-.03	.01	-.03	.04	-.06	.19	.02	.04	.16	-.10	.13
k	0	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{u}\hat{z}}(k)$		.90	-.07	-.06	.05	.03	.09	-.12	-.03	-.14	-.06	-.14	-.18	.12
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{z}}(k)$		.00	-.02	-.03	.03	.01	.10	.03	.20	.06	.05	.10	-.12	.12
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{u}\hat{z}}(k)$		.20	.17	.12	.10	.19	.00	.06	-.07	.02	-.07	-.16	-.17	.12
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{u}\hat{z}}(k)$		-.08	-.07	-.07	-.03	-.05	.02	-.06	.16	.05	.09	.18	-.01	.12

modells bei der Erzeugung von Post-Sample-Prognosen berücksichtigt werden. Eine direkte Übernahme des Noise-Modells des Mueller-Modells zur Erzeugung der Post-Sample-Prognosen ist jedoch wegen der von Mueller unterstellten Verfügbarkeit der Daten nicht sinnvoll.

Nach Mueller sind die Quartalsdaten für das verfügbare persönliche Einkommen nicht mit der gleichen Zügigkeit wie die des ICS veröffentlicht, sondern mit einem Lag von einem Quartal. Daher ist der Zeit-Index des verfügbaren persönlichen Einkommens $(t-2, t-1)$. Die gleiche Annahme muß auch für die Ausgabekategorien, die im Mueller-Modell als jeweilige abhängige Variable auftreten, getroffen werden. Bei der Prognose von $CDM_{t+1, t+2}$ bzw. $CAM_{t+1, t+2}$ zum Ende von Quartal t sind dann die Fehler der Prognosen von $CDM_{t, t+1}$ bzw. $CAM_{t, t+1}$ noch unbekannt. Der in Quartal t letzte vorliegende Prognosefehler ist derjenige in bezug auf $CDM_{t-2, t-1}$ bzw. $CAM_{t-2, t-1}$. Falls jedoch angenommen wird, die Daten der Ausgabekategorien seien mit gleicher Schnelligkeit wie die des ICS verfügbar, ist zum Ende von Quartal t auch der Prognosefehler von $CDM_{t-1, t}$ bzw. $CAM_{t-1, t}$ bekannt. Technisch unmöglich in Quartal t ist hingegen die Kenntnis des Fehlers der Prognose von $CDM_{t, t+1}$ bzw. $CAM_{t, t+1}$, da $CDM_{t, t+1}$ bzw. $CAM_{t, t+1}$ in Quartal t noch nicht realisiert ist.

Entsprechend können in t Prognosen von $CDM_{t+1, t+2}$ bzw. $CAM_{t+1, t+2}$ für Prognosedistanz $l = 3$ - wobei $CDM_{t-2, t-1}$ bzw. $CAM_{t-2, t-1}$ Prognoseursprung ist - oder für Prognosedistanz $l = 2$ - hier ist $CDM_{t-1, t}$ bzw. $CAM_{t-1, t}$

Prognoseursprung - erstellt werden. Technisch unmöglich ist in t die Prognose von $CDM_{t+1,t+2}$ bzw. $CAM_{t+1,t+2}$ für Prognosedistanz $l = 1$, da hier $CDM_{t,t+1}$ bzw. $CAM_{t,t+1}$ -Prognoseursprung sein müßte - dieser Wert ist in t noch nicht realisiert.

Im folgenden sind die Prognosen des Noise-Modells sowohl für Prognosedistanz $l = 2$ wie für $l = 3$ erzeugt, um den Einfluß der unterschiedlichen zeitlichen Verfügbarkeit der Prognosefehler zu verdeutlichen. Die Prognoseformeln für die einzelnen Prognosedistanzen sind in Tabelle 18 aufgeführt.

Tabelle 18

Die Prognoseformeln des Mueller-Modells¹⁾

1. Prognosedistanz $l = 2$

$$\begin{aligned} CDM_{t+1,t+2} &= -628 + .23YDM_{t-2,t-1} + .79ICS_t + 1.29U_{t-1,t} \\ &\quad - .59U_{t-2,t-1} \\ CAM_{t+1,t+2} &= -284 + .09YDM_{t-2,t-1} + .91ICS_t + .96U_{t-1,t} \\ &\quad - .45U_{t-2,t-1} \end{aligned}$$

2. Prognosedistanz $l = 3$

$$\begin{aligned} CDM_{t-1,t+2} &= -628 + .23YDM_{t-2,t-1} - .79ICS_t \\ &\quad + 1.12U_{t-2,t-1} - .58U_{t-3,t-2} \\ CAM_{t+1,t+2} &= -284 + .09YDM_{t-2,t-1} + .91ICS_t \\ &\quad + .67U_{t-2,t-1} - .37U_{t-3,t-2} \end{aligned}$$

Wie oben begründet, sind auch Prognosen des Mueller-Modells ohne Einbeziehung des Noise-Modells erstellt. Die Prognoseformel ist dann einfach die in (4.1) spezifizierte Gleichung wobei die in Tabelle 6 ausgewiesenen Schätzungen der Para-

1) Die Prognoseformeln sind mithilfe der in Abschnitt 4.2.4 vorgestellten Technik entwickelt.

meter verwendet werden.

3. Für den Vergleich mit den Prognosen des Mueller-Modells sind dem ARIMA-Modell die gleichen Bedingungen in bezug auf die Verfügbarkeit der Daten aufzuerlegen. Wenn die von Mueller angenommene Verzögerung der Veröffentlichung der Daten unterstellt wird, müssen in t Prognosen von $CDM_{t+1,t+2}$ bzw. $CAM_{t+1,t+2}$ für Prognosedistanz $l = 3$ erzeugt werden, wobei $CDM_{t-2,t-1}$ bzw. $CAM_{t-2,t-1}$ Prognoseursprung ist. Zusätzlich ist auch die Prognoseformel für Prognosedistanz $l = 2$ benutzt (Prognoseursprung ist hier $CDM_{t-1,t}$ bzw. $CAM_{t-1,t}$), die eine Bewertung unter der Annahme ermöglicht, die statistischen Behörden wiesen mit Abschluß jedes Quartals die Daten für dieses Quartal sofort aus. Die Prognoseformeln sind in Tabelle 19 aufgeführt.

Tabelle 19

Die Prognoseformeln des "naiven" Alternativmodells zum Mueller-Modell¹⁾

1. Prognosedistanz $l = 2$

$$CDM_{t-1,t+2}$$

$$\hat{X}_t(2) = X_t + .94U_t - .31U_{t-2} - .60U_{t-3} - .29U_{t-4}$$

$$CAM_{t-1,t+2}$$

$$\hat{X}_t(2) = X_t + .93U_t - .40U_{t-2} - .77U_{t-3} - .37U_{t-4}$$

2. Prognosedistanz $l = 3$

$$CDM_{t-1,t+2}$$

$$\begin{aligned} \hat{X}_t(3) = X_t + .94U_t - .31U_{t-1} - .60U_{t-2} - .60U_{t-3} \\ - .29U_{t-4} \end{aligned}$$

$$CAM_{t-1,t+2}$$

$$\begin{aligned} \hat{X}_t(3) = X_t - .93U_t - .40U_{t-1} - .77U_{t-2} - .77U_{t-3} \\ - .37U_{t-4} \end{aligned}$$

1) Die Prognoseformeln sind mithilfe der in Abschnitt 424 vorgestellten Technik entwickelt.

4562 Die Prognoseformeln des Fair-Modells, des "naiven"
Alternativmodells und des univariaten Modells für
FEX_t

1. Die Prognoseformel des Fair-Modells kann das in der Sample-Periode ermittelte Noise-Modell ohne Veränderungen übernehmen, da Fair keine Verzögerung des Datenausweises durch statistische Behörden, die über ein Quartal hinausgeht, unterstellt. Die Prognoseformeln sind in Tabelle 20 aufgeführt.

Tabelle 20

Die Prognoseformeln des Fair-Modells¹⁾

$$CDF_t = - 3.981 + .099\overline{GNP}_t + .015ICS_{t-1} + .009ICS_{t-2} \\ + .72U_{t-1}$$

$$CAF_t = - 4.945 + .045\overline{GNP}_t + .031ICS_{t-1} + .012ICS_{t-2} \\ + .43U_{t-1}$$

Zur Erstellung von Prognosen, bei denen das Noise-Modell nicht verwendet wird, kann die in (4.7) spezifizierte Gleichung, unter Einbeziehung der in Tabelle 12 ausgewiesenen Schätzungen der Parameter, herangezogen werden.

2. In Tabelle 21 sind die Prognoseformeln der ARIMA-Modelle für CDF_t , CAF_t und FEX_t aufgeführt. Wie für das Fair-Modell beziehen sich die Prognoseformeln jeweils auf Prognosedistanz $l = 1$.

46 Die Prognosegüte der Modelle

461 Die Prognosegüte des Mueller-Modells

1) Die Prognoseformeln sind mithilfe der in Abschnitt 424 vorgestellten Technik entwickelt.

Tabelle 21

Die Prognoseformeln des "naiven" Alternativmodells zum Fair-Modell und des univariaten Modells für FEX_t¹⁾

CDF_t

$$\hat{X}_t(1) = X_t + .29$$

CAF_t

$$\hat{X}_t(1) = X_t + .16$$

FEX_t

$$\hat{X}_t(1) = 1.30X_t - .08X_{t-1} + .22X_{t-2}$$

4611 Analyse auf der objektiven Ebene

In Tabelle 22 sind der Mittelwert der Prognosefehler sowie der MSE der Prognosen der verschiedenen Versionen des Mueller-Modells und des ARIMA-Modells ausgewiesen. Außerdem sind die MSE in Prozent des jeweils niedrigsten MSE aufgeführt, um die relative Größenordnung darzustellen.

1. Aufgrund der in Tabelle 22 ausgewiesenen Werte lassen sich die folgenden Feststellungen treffen:

- Das Mueller-Modell erzeugt in der betrachteten Post-Sample-Periode für beide Ausgabekategorien Prognosen mit geringerem MSE als das ARIMA-Modell für gleiche Prognosedistanzen.
- Der relative Unterschied der MSE ist dabei für Autoausgaben höher als für Gebrauchsgüterausgaben: die

1) Die Prognoseformeln sind mithilfe der in Abschnitt 424 vorgestellten Technik entwickelt.

Tabelle 22

Mittelwert der Prognosefehler und absoluter und relativer MSE der Prognosen der verschiedenen Versionen des Mueller-Modells und des "naiven" Alternativmodells

Post-Sample-Periode: 1973.1 - 1976.3

	Mittelwert der Prognose- sefehler	MSE absolut in Prozent des niedrigsten MSE
1. Abhängige Variable: $CDM_{t+1,t+2}$		
Mueller-Modell inkl. Noise- Modell, Prognosedistanz 1 = 2	- 4.3	1249
Mueller-Modell inkl. Noise- Modell, Prognosedistanz 1 = 3	- 3.7	2197
Mueller-Modell ohne Noise- Modell	- 12.7	2430
ARIMA-Modell, Prognosedistanz 1 = 2	13.6	1586
ARIMA-Modell, Prognosedistanz 1 = 3	19.4	3446
2. Abhängige Variable: $CAM_{t+1,t+2}$		
Mueller-Modell inkl. Noise- Modell, Prognosedistanz 1 = 2	6.2	655
Mueller-Modell inkl. Noise- Modell, Prognosedistanz 1 = 3	7.8	1043
Mueller-Modell ohne Noise- Modell	10.6	1384
ARIMA-Modell, Prognosedistanz 1 = 2	9.7	1586
ARIMA-Modell, Prognosedistanz 1 = 3	14.5	2070
Legende:		
$CDM_{t+1,t+2}$	Consumer durable goods expenditures in quarters (t + 1) and (t + 2) in constant dollars of 1972;	
$CAM_{t+1,t+2}$	Consumer expenditures on motor vehicles and parts in quarters (t + 1) and (t + 2) in constant dollars of 1972.	
$CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$	sind für die Zahl der Familien sowie saisonal adjustiert.	

Prognosen des ARIMA-Modells, Prognosedistanz $l = 2$, weisen bei $CAM_{t-1,t+2}$ einen MSE auf, der um 43 % über dem der Prognosen des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 2$, liegt; bei $CDM_{t+1,t-2}$ sind es 27 %. Für Prognosedistanz $l = 3$ ist der relative Unterschied des MSE der Prognosen des Mueller-Modells inkl. Noise-Modell im Vergleich zu dem des ARIMA-Modells bei $CAM_{t+1,t+2}$ 157 %, bei $CDM_{t+1,t+2}$ 100 %.¹⁾

- Das ARIMA-Modell, Prognosedistanz $l = 3$, prognostiziert beide Ausgabekategorien mit einem höheren MSE als das Mueller-Modell ohne Noise-Modell; bei $CAM_{t+1,t+2}$ beträgt der relative Unterschied 105 %, bei $CDM_{t+1,t+2}$ 81 %.¹⁾
- Die Berücksichtigung eines Noise-Modells verringert den MSE der Prognosen des Mueller-Modells. Der relative Unterschied liegt dabei für $CAM_{t+1,t+2}$ bei 111 % (Prognosedistanz $l = 2$) bzw. 52 % (Prognosedistanz $l = 3$) und für $CDM_{t+1,t+2}$ bei 95 % (Prognosedistanz $l = 2$) bzw. 19 % (Prognosedistanz $l = 3$).¹⁾
- Ausnahmslos besitzen Prognosen für Prognosedistanz $l = 2$ niedrigere MSE als solche des jeweils gleichen Modells für Prognosedistanz $l = 3$.²⁾ Der relative Unterschied beträgt bei $CAM_{t+1,t+2}$ für das Mueller-Modell 59 % und für das ARIMA-Modell 173 %. Bei

1) Jeweils in Prozent des MSE des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 2$.

2) Für ARIMA-Modelle ist eine absinkende Prognosegüte bei ansteigender Prognosedistanz eine bekannte Erscheinung: "As well is known, such schemes (autoregressive univariate models) can deteriorate badly if used to forecast more than one period ahead." Goldfeld (1972), S. 927. Vgl. auch Mincer/Zarnowitz (1969), S. 40, Granger/Newbold (1977), S. 181. Da die jeweils jüngste Vergangenheit einer Zeitreihe in ARIMA-Modellen die stärkste Gewichtung erhält, ist dieser Sachverhalt einfach erklärbar.

$CDM_{t+1,t+2}$ ist der relative Unterschied 76 % (Mueller-Modell) bzw. 149 % (ARIMA-Modell).¹⁾

2. Um die Signifikanz der Unterschiede der MSE der einzelnen Modelle zu testen, ist das von Ashley/Granger/Schmalensee vorgeschlagene Verfahren verwendet, das der Möglichkeit der Autokorrelation und eines von Null abweichenden Mittelwertes in den Reihen der Prognosefehler Rechnung trägt. Wie bei Ashley/Granger/Schmalensee sind die Regressionen mithilfe des Cochrane/Orcutt-Verfahrens durchgeführt, wobei ein autoregressiver Prozeß erster Ordnung in der stochastischen Größe der Regressionsgleichung unterstellt ist.

Tabelle 23 weist für $CDM_{t+1,t+2}$ und $CAM_{t+1,t+2}$ die Ergebnisse aller Regressionen, d.h. des paarweisen Vergleichs der MSE der Prognosen aller Modelle, aus. In der Zeile (Spalte) ist jeweils das Modell mit dem im Paarvergleich höheren (niedrigeren) MSE aufgeführt. Die Prognosefehler des Modells mit dem höheren (niedrigeren) MSE sind dabei als die e_{1t} -(e_{2t} -)Reihen bei der Berechnung von de_t und se_t behandelt. e_{1t} , e_{2t} , de_t und se_t sind mithilfe der Gleichungen (4.63) und (4.64) definiert. Das Feld in der ersten Zeile und zweiten Spalte nennt also z.B. das Ergebnis der Regression von de_t auf se_t , wobei die e_{1t} -Reihe die der Prognosefehler des Mueller-Modells ohne Noise-Modell und die e_{2t} -Reihe die der Prognosefehler des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 3$, ist.

3. Offensichtlich entspricht ein Teil der in Tabelle 23 ausgewiesenen Ergebnisse nicht den Erwartungen. So sollte bei spielweise in den Feldern nur entweder "nicht signifikant"

1) Jeweils in Prozent des MSE des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 2$.

Ergebnisse der Signifikanz-Tests der Unterschiede der MSE der Prognosen der verschiedenen Versionen des Mueller-Modells und des "naiven" Alternativmodells

Post-Sample-Periode: 1973.1 - 1976.3

Modell mit höherem MSE		Modell mit niedrigerem MSE	
1. Abhängige Variable: CDM _{t+1,t+2}		Mueller-Modell inkl. Noise-Modell, Prognosedistanz 1 = 2	
Mueller-Modell inkl. Noise-Modell, Prognosedistanz 1 = 2		n.s.	
Mueller-Modell inkl. Noise-Modell, Prognosedistanz 1 = 3		n.s.	
Mueller-Modell ohne Noise-Modell		n.s.	
ARIMA-Modell, Prognosedistanz 1 = 2		n.s.	
ARIMA-Modell, Prognosedistanz 1 = 3		n.s.	
2. Abhängige Variable: CAM _{t+1,t+2}		Mueller-Modell inkl. Noise-Modell, Prognosedistanz 1 = 2	
Mueller-Modell inkl. Noise-Modell, Prognosedistanz 1 = 2		n.s.	
Mueller-Modell inkl. Noise-Modell, Prognosedistanz 1 = 3		n.s.	
Mueller-Modell ohne Noise-Modell		n.s.	
ARIMA-Modell, Prognosedistanz 1 = 2		s. .05	
ARIMA-Modell, Prognosedistanz 1 = 3		s. .05	
Legende:		neg. s. .05	
CDM _{t+1,t+2} , CAM _{t+1,t+2} s. Tabelle 31;		neg. s. .05	
n.s. nicht signifikant;		neg. s. .05	
s. .05/s. .10 signifikant (Irrtumswahrscheinlichkeit .05/.10);		neg. s. .05 negativ signifikant (Irrtumswahrscheinlichkeit .05).	

oder "signifikant" stehen, wobei das erstgenannte Ergebnis einen nicht signifikanten Unterschied zweier MSE und das zweitgenannte einen signifikanten (positiven) Unterschied zwischen dem MSE des in der Zeile und dem MSE des in der Spalte aufgeführten Modells anzeigen würde. Es könnte ferner zu erwarten sein, daß - falls $MSE_1 > MSE_2 > MSE_3$ (die Indizes bezeichnen hier jeweils ein bestimmtes Modell) - der Test dann einen signifikanten Unterschied zwischen MSE_1 und MSE_3 feststellt, wenn er die Signifikanz der Differenz zwischen MSE_1 und MSE_2 bestätigt.

Im Gegensatz hierzu ist bei $CAM_{t+1,t+2}$ eine signifikant negative Schätzung des Parameters von se_t für das Mueller-Modell ohne Noise-Modell (Prognosefehler = e_{1t}) und das ARIMA-Modell, Prognosedistanz $l = 2$, (Prognosefehler = e_{2t}) zu verzeichnen (Irrtumswahrscheinlichkeit .05). Dies wäre folgerichtig im Sinne einer Überlegenheit des Mueller-Modells ohne Noise-Modell gegenüber dem ARIMA-Modell, Prognosedistanz $l = 2$, zu interpretieren, obwohl der MSE des ersten über dem des zweiten liegt. Ferner fällt auf, daß für beide Ausgabekategorien der MSE des Mueller-Modells ohne Noise-Modell als signifikant niedriger als der des ARIMA-Modells, Prognosedistanz $l = 3$, eingestuft ist, während die MSE des ARIMA-Modells, Prognosedistanz $l = 3$, und des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 3$, als nicht signifikant unterschieden bezeichnet werden. Diese Aussage steht in Gegensatz zu der Rangfolge der tatsächlichen Größensordnungen der MSE, wie in Tabelle 22 ausgewiesen.

Es lassen sich leicht andere Ergebnisse aus Tabelle 23 anführen, die zu ähnlichen Unstimmigkeiten führen. Offensichtlich kehrt der MSE-Test in einigen Fällen die Rangfolge der

MSE der Prognosen, und damit die der Prognosegüte der Modelle, um.

4. Die hier auftretenden Unstimmigkeiten stehen in direktem Zusammenhang mit der Zeitreihennatur der Prognosefehler, die wiederum als Indiz für die Prognosegüte eines Modells angesehen werden kann. Da die Prognosegüte der Modelle zentraler Aspekt der vorliegenden Beurteilung ist, muß den Gründen des Versagens des MSE-Tests Aufmerksamkeit geschenkt werden.

Die Lösung des Problems liegt in der Behandlung der Autokorrelation der stochastischen Größe bei der Regression von de_t auf se_t . Das Cochrane/Orcutt-Verfahren transformiert die de_t - und se_t -Reihen nach Maßgabe des geschätzten autoregressiven Parameters der stochastischen Größe; mit den de_t - und se_t -Reihen werden natürlich auch deren Summanden, die Reihen der Prognosefehler e_{1t} und e_{2t} , transformiert. Durch diese Transformation verändert sich die autokorrelative Struktur der Prognosefehler, u.z. in aller Regel in Richtung auf weisses Rauschen hin. Es erscheint unmittelbar plausibel, als Ergebnis der veränderten autokorrelativen Struktur der Prognosefehler auch eine veränderte Prognosegüte eines Modells zu erwarten. Es fragt sich, ob diese Veränderung der autokorrelativen Struktur der Prognosefehler wünschenswert ist.

Für eine Veränderung spricht die Überlegung, daß einem Benutzer der verschiedenen Versionen des Mueller- bzw. ARIMA-Modells die Autokorrelation der Prognosefehler auf Dauer nicht verborgen bliebe, jedenfalls dann nicht, wenn ein relativ einfach aufzudeckendes autokorrelatives Muster wie das eines autoregressiven Prozesses erster Ordnung vorliegt. Eine Berücksichtigung der autokorrelativen Struktur der Prognosefehler bei der Erstellung neuer Prognosen könnte dann

zu einer höheren Prognosegüte führen, denn offensichtlich enthalten vergangene Prognosefehler Informationen über zukünftige Prognosefehler.

Gegen eine Veränderung der autokorrelativen Struktur der Prognosefehler spricht die technisch bedingte Unvermeidbarkeit von Autokorrelation der Prognosefehler der hier verwendeten Modelle.¹⁾ Eine Autokorrelation der Prognosefehler des Mueller-Modells ohne Noise-Modell ist für beide Ausgabekategorien deswegen zu erwarten, weil das in der Sample-Periode angewandte Schätzverfahren einen autoregressiven Prozeß zweiter Ordnung der stochastischen Größe aufdeckte, der bei der Erstellung der Post-Sample-Prognosen unberücksichtigt blieb. Eine nachträgliche Veränderung dieser autokorrelativen Struktur und damit eine Verbesserung der Prognosegüte des Mueller-Modells ohne Noise-Modell wäre unerwünscht, da die hinter der Nichtberücksichtigung des Noise-Modells stehende Absicht ja gerade das Aufzeigen der Suboptimalität der Prognosen gegenüber Modellen ist, die die in der Sample-Periode identifizierte autokorrelative Struktur der stochastischen Größe in die Erstellung der Post-Sample-Prognosen einbeziehen.

Das Versagen des MSE-Tests beruht also zumindestens teilweise²⁾ auf der Nichtberücksichtigung des Noise-Modells bei de

- 1) Die hier beschriebene Problematik des von Ashley/Granger, Schmalensee empfohlenen MSE-Tests ist von Prof. Granger in einem persönlichen Gespräch am 3.3.1978 bestätigt worden.
- 2) Es lassen sich weitere Gründe anführen, die für Autokorrelation der Prognosefehler sorgen könnten. Die Prognosefehler von ARIMA-Modellen sind für Prognosedistanzen $l > 1$ im allgemeinen autokorreliert (vgl. Box/Jenkins (1976), S. 158); diese Autokorrelation sollte, sofern sie kurzfristiger Natur ist, wegen der dem Mueller-Modell zugrundeliegenden Annahmen in bezug auf die Verfügbarkeit der Daten nicht ohne weiteres durch eine Transformation der beim Cochrane/Orcutt-Verfahren üblichen Form ausgeräumt werden. Schließlich könnte die Autokorrelation der Prognosefehler auch durch misspezifizierte Modelle entstehen. Dieser Gedanke ist - in anderem Zusammenhang - in Abschnitt 5.5 systematisch dargestellt.

Erstellung von Post-Sample-Prognosen. Damit wird indirekt noch einmal die Kritik an den Untersuchungen von Juster (1969), Burch/Stekler (1969), Hymans (1970) und Fair (1972) gestützt, deren Post-Sample-Prognosen der in der Sample-Periode zu beobachtenden Autokorrelation der Residuen keine Aufmerksamkeit schenken.

5. Die in Tabelle 23 ausgewiesenen Ergebnisse bestätigen unter den oben begründeten Vorbehalten die wesentlichen bisher gezogenen Schlußfolgerungen:

- Der MSE der Prognosen des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 2$, ist für Autoausgaben signifikant niedriger als die der Prognosen der ARIMA-Modelle für Prognosedistanzen $l = 2$ und $l = 3$.
- Wiederum erscheint der relative Vorsprung des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 2$, stärker bei Autoausgaben als bei Gebrauchsgüterausgaben.
- Der MSE der Prognosen des Mueller-Modells ohne Noise-Modell ist für beide Ausgabekategorien signifikant niedriger als der der Prognosen des ARIMA-Modells, Prognosedistanz $l = 3$.
- Kürzere Prognosedistanzen wirken sich für beide Ausgabekategorien beim ARIMA-Modell in signifikant niedrigeren MSE aus.

4612 Analyse auf der subjektiven Ebene

Die Zeichnungen 4 bis 15 ermöglichen eine Beurteilung des

Erscheinungsbildes der Prognosen und Prognosefehler der verschiedenen Versionen des Mueller-Modells und des ARIMA-Modells. Bei der Interpretation der Zeichnungen 12 bis 15 ist zu beachten, daß ein negativer (positiver) Prognosefehler eine Unterschätzung (Überschätzung) der tatsächlichen Werte anzeigt.

1. Wie die Zeichnungen 6 und 7 ausweisen, melden das Mueller-Modell inkl. Noise-Modell und das ARIMA-Modell, jeweils Prognosedistanz $l = 3$, den Abstieg der tatsächlichen Werte zu Beginn der Post-Sample-Periode mit einer Verzögerung von ca. 2 Perioden. Diese Aussage gilt für beide Ausgabekategorien. Bei dem Umkehrpunkt der tatsächlichen Werte in 1974.4 will es scheinen, als werde hier die Entwicklung von beiden Modellen richtig antizipiert, denn die Prognosen des Mueller-Modells inkl. Noise-Modell weisen exakt in 1974.4 auf ein erneutes Ansteigen hin, und die Prognosen des ARIMA-Modells zeigen bereits in 1974.3 wieder ansteigende Tendenz. Eine nähere Inspektion der Zeichnungen 6 und 7 läßt jedoch eher die Vermutung zu, beide Modelle "prognostizierten" nur mit Verspätung die kurze Aufwärtsbewegung der tatsächlichen Werte in 1974.1. Hierauf deutet insbesondere die erneute Abwärtstendenz der Prognosen beider Modelle in 1975.1, der kein entsprechendes Verhalten der tatsächlichen Werte gegenübersteht. Diese Abwärtstendenz scheint eher die Reaktion auf das Absinken der tatsächlichen Werte in 1974.2 zu sein. Das erneute Ansteigen der tatsächlichen Werte in 1974.4 spiegelt sich in den Prognosen beider Modelle somit erst in 1975.2 wider. Die Prognosen beider Modelle "antizipieren" die Umkehrpunkte der tatsächlichen Gebrauchsgüter- und Autoausgaben in der Post-Sample-Periode also nur mit einer Verzögerung von ca. 2 Perioden.

Beim Vergleich der Prognosen beider Modelle kann das präzi-

sere Verhalten der Prognosen des Mueller-Modells inkl. Noise-Modell, das bereits bei der MSE-Analyse auffiel, festgestellt werden (vgl. auch die Zeichnungen 14 und 15). Im besonderen für Autoausgaben begleiten die Prognosen des Mueller-Modells inkl. Noise-Modell die tatsächlichen Werte enger als die Prognosen des ARIMA-Modells. Dagegen ist für Gebrauchsgüterausgaben ab 1975.2 eine Überlegenheit des ARIMA-Modells festzustellen, die jedoch die im ersten Teil der Post-Sample-Periode gezeigten stärkeren Abweichungen nicht auszugleichen vermag.

Wie aus den Zeichnungen 6 und 7 und deutlicher noch aus den Zeichnungen 14 und 15 ersichtlich ist, ähneln sich die Erscheinungsbilder der Prognosen und damit die der Prognosefehler beider Modelle. Besonders für Autoausgaben ist die hohe Korrelation der Prognosefehler optisch erkennbar. Diese Übereinstimmung scheint im wesentlichen durch die Unfähigkeit beider Modelle verursacht, den starken Abfall der tatsächlichen Werte von 1973.1 - 1974.4 sowie ihren erneuten Anstieg von 1975.1 in Richtung und Ausmaß befriedigend zu antizipieren. Die Faktoren, die für das Verhalten der Gebrauchsgüter- und Autoausgaben in der Post-Sample-Periode verantwortlich sind, werden offensichtlich nur in geringem Umfang in den beiden Modellen repräsentiert.

2. Bei den Prognosen des Mueller-Modells inkl. Noise-Modell und des ARIMA-Modells, jeweils Prognosedistanz $l = 2$, (Zeichnungen 4 und 5) fällt im Vergleich zu denen der gleichen Modelle für Prognosedistanz $l = 3$ die bessere Anpassung an die tatsächliche Ausgabenentwicklung auf. Wie die Gegenüberstellung der Zeichnungen 4 und 6 bzw. 5 und 7 zeigt, ist jeweils über die gesamte Post-Sample-Periode eine bessere Prognosegüte für die kürzere Prognosedistanz erzielt.

Allerdings antizipieren die Prognosen hier ebenso wenig wie die für Prognosedistanz $l = 3$ die Umkehrpunkte der tatsächlichen Werte in 1973.1 und 1974.4. Die Prognosen beider Modelle erreichen ihre positiven bzw. negativen Gipfelpunkte um ca. eine Periode verzögert, was immerhin eine Verbesserung um eine Periode gegenüber den Prognosen für Prognosedistanz $l = 3$ darstellt. Das ARIMA-Modell reagiert jedoch schneller (bereits in 1975.1) auf den Umkehrpunkt der tatsächlichen Werte (in 1974.4) als das Mueller-Modell inkl. Noise-Modell, das auch für 1975.2 noch absinkende Werte prognostiziert.

Generell könnte ausschließlich aufgrund der Zeichnungen der Prognosen (4 und 5) und Prognosefehler (12 und 13) nicht festgestellt werden, welches Modell eine höhere Prognosegüte aufweist. Für beide Ausgabekategorien ist das Erscheinungsbild der Prognosen des ARIMA-Modells etwas unruhiger als das der Prognosen des Mueller-Modells inkl. Noise-Modell, aber beide Prognoseserien wechseln sich in der geringsten Entfernung zu den tatsächlichen Werten ab, und eine Überlegenheit des Mueller-Modells inkl. Noise-Modell - wie aufgrund der MSE-Analyse festgestellt - läßt sich hier nicht ohne weiteres bestätigen. Offensichtlich wird die Prognosegüte des ARIMA-Modells durch die Zugrundelegung einer quadratischen Verlustfunktion für seine schlechte Prognose in 1974.4 besonders stark beeinträchtigt.

Die Zeichnungen der Prognosefehler (12 und 13) bestätigen den Eindruck der Ähnlichkeit der Prognosen des Mueller-Modells inkl. Noise-Modell und des ARIMA-Modells auch für Prognosedistanz $l = 2$. Im ersten Teil der Post-Sample-Periode - bis 1975.1 - überschätzen beide Modelle die tatsächlichen Werte, im zweiten Teil unterschätzen sie sie.


Damit wird erneut die Ansicht gestützt, daß keines der Modelle in befriedigendem Maße die Faktoren, die das Verhalten der tatsächlichen Werte in der Post-Sample-Periode steuern, repräsentiert. Diese Aussage gilt im besonderen für Autoausgaben, für die die Modelle offensichtlich noch stärker korrelierte Prognosen als für Gebrauchsgüteraussgaben erstellen.

3. Von Interesse ist schließlich die Gegenüberstellung der Prognosen des Mueller-Modells inkl. Noise-Modell, Prognosedistanzen $l = 2$ und $l = 3$, mit denen des Mueller-Modells ohne Noise-Modell, aus der sich weitere Hinweise auf die Bedeutung des Noise-Modells erschließen lassen. Zunächst ist aus den Zeichnungen⁸ und 9 die geringe Sensibilität der Prognosen des Mueller-Modells ohne Noise-Modell für die Entwicklung der tatsächlichen Werte zu entnehmen. Die Prognosen zeichnen für beide Ausgabekategorien eine schwach gekrümmte, s-förmige Linie, die nur wenig von der Dynamik der tatsächlichen Werte in der Post-Sample-Periode errahnen läßt. Das gesamte Erscheinungsbild der Prognosen deutet auf eine hohe Autokorrelation der Prognosefehler. Immerhin fangen die Prognosen des Mueller-Modells ohne Noise-Modell die allgemeinen Kennzeichen der Entwicklung der tatsächlichen Werte - das Absinken bis ca. 1974.4 und das darauffolgende Ansteigen - ein, wenn auch ohne antizipative Fähigkeit für den Umkehrpunkt.

Die Prognosen der Modelle, die das Noise-Modell einschließen, scheinen wesentlich genauer den Verlauf der tatsächlichen Werte zu beschreiben. Trotz der ihnen anhaftenden Mängel - keine Antizipation der Umkehrpunkte - weist ihr Erscheinungsbild jeweils vergleichsweise hohe Ähnlichkeit mit den tatsächlichen Werten auf, wobei die kürzere Progno-

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, L=2

PROGNOSEN



Legende:

CDM = CDM_{t+1, t+2}

Consumer durable goods expenditures in quarters (t + 1) and (t + 2) in constant dollars of 1972;

PGMZ = PGMZ_{t+1, t+2}


Prognose von CDM_{t+1, t+2} mithilfe des Mueller-Modells inkl. Noise-Modell,

Prognosedistanz 1 = 2;

PGMAZ = PGMAZ_{t+1, t+2} mithilfe des ARIMA-Modells, Prognosedistanz


CDM_{t+1, t+2} ist für die Zahl der Familien sowie saisonal adjustiert.

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, L=2



PROGNOSEN

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, $L=3$



Legende:

$CDM = CDM_{t+1, t+2}$

Consumer durable goods expenditures in quarters $(t+1)$ and $(t+2)$ in constant dollars of 1972;

$PGMD = PGMD_{t+1, t+2}$


Prognose von $CDM_{t+1, t+2}$ mithilfe des Mueller-Modells inkl. Noise-Modell, Prognosestanz $l = 3$;

$PGHAD = PGHAD_{t+1, t+2}$

Prognose von $CDM_{t+1, t+2}$ mithilfe des ARIMA-Modells, Prognosestanz $l = 3$.


$CDM_{t+1, t+2}$ ist für die Zahl der Familien sowie saisonal adjustiert

PROGNOSEN

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, $L=3$ 

PROGNOSEN

MUELLER-MODELL INKL. NOISE-MODELL, L=2, VS. OHNE NOISE



Legende:

CDM = $CDM_{t+1, t+2}$

PGMZ = $PGMZ_{t+1, t+2}$

PGMO = $PGMO_{t+1, t+2}$

Consumer durable goods expenditures in quarters $(t+1)$ and $(t+2)$ in constant dollars of 1972;

Prognose von $CDM_{t+1, t+2}$ mithilfe des Mueller-Modells inkl. Noise-Modell,


Prognosedistanz 1 = 2;

Prognose von $CDM_{t+1, t+2}$ mithilfe des Mueller-Modells ohne Noise-Modell.

Zeichnung 9


PROGNOSEN

MUELLER-MODELL INKL. NOISE-MODELL, 1-2, VS. OHNE NOISE



PROGNOSEN

MUELLER-MODELL INKL. NOISE-MODELL, L=3, VS. OHNE NOISE




Legende:

CDM = CDM_{t+1, t+2}PGMD = PGMD_{t+1, t+2}PGMO = PGMO_{t+1, t+2}CDM_{t+1, t+2} ist für die Zahl der Familien sowie saisonal adjustiert.

Zeichnung 11

PROGNOSEN

MUELLER-MODELL INKL. NOISE-MODELL, $L=3$, VS. OHNE NOISE


Legende:

CAM = CAM_{t+1, t+2}PAMD = PAMD_{t+1, t+2}PAMO = PAMO_{t+1, t+2}CAM_{t+1, t+2} ist für die Zahl der Familien sowie saisonal adjustiert.

Consumer expenditures on motor vehicles and parts in quarters (t + 1) and (t + 2) in constant dollars of 1972;
 Prognose von CAM_{t+1, t+2} mithilfe des Mueller-Modells inkl. Noise-Modell,
 Prognosedistanz $l = 3$;
 Prognose von CAM_{t+1, t+2} mithilfe des Mueller-Modells ohne Noise-Modell.

PROGNOSEFEHLER

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, L=2



Legende:

GMZ = $GMZ_{t+1, t+2}$

Prognosefehler des Mueller-Modells inkl. Noise-Modell, Prognosedistanz 1 = 2, in bezug auf $CDM_{t+1, t+2}$

GMAZ = $GMAZ_{t+1, t+2}$


Prognosefehler des ARIMA-Modells, Prognosedistanz 1 = 2, in bezug auf $CDM_{t+1, t+2}$

$CDM_{t+1, t+2}$

Consumer durable goods expenditures in quarters (t + 1) and (t + 2) in constant dollars of 1972.

PROGNOSEFEHLER

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, L=2



Legende:

AMZ = $AMZ_{t+1, t+2}$

Prognosefehler des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 2$, in bezug auf $CAN_{t+1, t+2}$

AMAZ = $AMAZ_{t+1, t+2}$

Prognosefehler des ARIMA-Modells, Prognosedistanz $l = 2$, in bezug auf $CAN_{t+1, t+2}$

$CAN_{t+1, t+2}$


Consumer expenditures on motor vehicles and parts in quarters $(t + 1)$ and $(t + 2)$ in constant dollars of 1972.

$CAN_{t+1, t+2}$ ist für die Zahl der Familien sowie saisonal adjustiert.

Zeichnung 14

PROGNOSEFEHLER

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, L=3




Prognosefehler des Mueller-Modells inkl. Noise-Modell, Prognosedistanz 1 = 3, in bezug auf $CDM_{t+1, t+2}$

Prognosefehler des ARIMA-Modells, Prognosedistanz 1 = 3, in bezug auf $CDM_{t+1, t+2}$

Consumer durable goods expenditures in quarters $(t+1)$ and $(t+2)$ in constant dollars of 1972.

ist für die Zahl der Familien sowie saisonal adjustiert.

PROGNOSEFEHLER

MUELLER-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL, $L=3$ 

Legende:

AMD = $AMD_{t+1, t+2}$ Prognosefehler des Mueller-Modells inkl. Noise-Modell, Prognosedistanz $l = 3$, in bezug auf $CAM_{t+1, t+2}$ AMAD = $AMAD_{t+1, t+2}$ Prognosefehler des ARIMA-Modells, Prognosedistanz $l = 3$, in bezug auf $CAM_{t+1, t+2}$ $CAM_{t+1, t+2}$ Consumer expenditures on motor vehicles and parts in quarters $(t+1)$ and $(t+2)$ in constant dollars of 1972. $CAM_{t+1, t+2}$ ist für die Zahl der Familien sowie saisonal adjustiert.

sedistanz zu einer noch engeren Anpassung führt.

Die Ergebnisse der MSE-Analyse, die die Notwendigkeit der Berücksichtigung eines Noise-Modells bereits andeuteten, können somit aufgrund der subjektiven Analyse als bestätigt gelten.

462 Die Prognosegüte des Fair-Modells

4621 Analyse auf der objektiven Ebene

Tabelle 24 weist den Mittelwert der Prognosefehler sowie den MSE der Prognosen der verschiedenen Versionen des Fair-Modells und des ARIMA-Modells aus. Die MSE sind in Tabelle 24 auch in Prozent des niedrigsten MSE aufgeführt, um eine Vorstellung von ihrer relativen Größenordnung zu vermitteln.

1. Es lassen sich die folgenden Schlußfolgerungen ziehen:

- Das Fair-Modell inkl. Noise-Modell erzeugt für beide Ausgabekategorien Prognosen mit geringerem MSE als das ARIMA-Modell.
- Der relative Abstand zwischen dem MSE des Fair-Modells inkl. Noise-Modell und dem des ARIMA-Modells ist für beide Ausgabekategorien ungefähr gleich.
- Das ARIMA-Modell produziert für Gebrauchsgüterausgaben bzw. Autoausgaben Prognosen mit 68 % bzw. 41 % niedrigerem MSE als das Fair-Modell ohne Noise-Modell.¹⁾
- Entscheidend für die gute Platzierung des Fair-Modells

1) Jeweils in Prozent des MSE des Fair-Modells inkl. Noise-Modell.

Mittelwert der Prognosefehler und absoluter und relativer MSE der Prognosen der verschiedenen Versionen des Fair-Modells und des "naïven" Alternativmodells

Post-Sample-Periode: 1973.1 - 1976.3

	Mittelwert der Prognose- fehler	MSE absolut in Prozent des niedrigsten MSE
1. Abhängige Variable: CDF_t		
Fair-Modell inkl. Noise-Modell	- .13	1.48 100
Fair-Modell ohne Noise-Modell	- .45	2.81 190
ARIMA-Modell	- .33	1.81 120
2. Abhängige Variable: CAF_t		
Fair-Modell inkl. Noise-Modell	.04	1.06 100
Fair-Modell ohne Noise-Modell	.09	1.77 167
ARIMA-Modell	- 2.38	1.34 126

Legende:

CDF_t Consumer durable goods expenditures in quarter t in billions of current dollars;
 CAF_t Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars.
 CDF_t und CAF_t sind saisonal adjustiert.

inkl. Noise-Modell ist die Berücksichtigung des Noise-Modells. Ohne Noise-Modell erzeugt das Fair-Modell Prognosen der Gebrauchsgüter- bzw. Autoausgaben mit 90 % bzw. 67 % höherem MSE als das Fair-Modell inkl. Noise-Modell und mit 68 % bzw. 41 % höherem MSE als das ARIMA-Modell.¹⁾

2. Um die Signifikanz der Unterschiede der MSE zu beurteilen ist wiederum der von Ashley/Granger/Schmalensee empfohlene Test verwendet. Die Ergebnisse der Regressionen sind in Tabelle 25 aufgeführt. Die Schätzungen basieren auf dem Cochrane/Orcutt-Verfahren, wobei ein autoregressiver Prozeß erster Ordnung in der stochastischen Größe unterstellt ist. Tabelle 25 ist in gleicher Weise wie Tabelle 23 zu lesen, d.h. in der Spalte (Zeile) ist jeweils das Modell mit dem im Paarvergleich höheren (niedrigeren) MSE genannt.

3. Die Ergebnisse des Tests können angesichts der oben gemachten Ausführungen nicht überraschen. Die Anwendung des Cochrane/Orcutt-Verfahrens verändert die autokorrelative Struktur der Prognosefehler, was wiederum zu einer Verbesserung der Prognosegüte führt. So ist Tabelle 25 z.B. eine signifikant bessere Prognosegüte des Fair-Modells ohne Noise-Modell im Vergleich zu der des ARIMA-Modells zu entnehmen (Irrtumswahrscheinlichkeit .10) - ein Ergebnis, das die Reihenfolge der in Tabelle 24 ausgewiesenen MSE umkehrt. Dieser Effekt geht mit hoher Wahrscheinlichkeit auf die Nichtbeachtung der autokorrelativen Struktur der Prognosefehler beim Fair-Modell ohne Noise-Modell zurück. Die Prognosegüte des Fair-Modells verbessert sich, wenn das Noise-Modell berücksichtigt wird.

Im übrigen ist aus Tabelle 25 zu entnehmen, daß das Fair-

1) Jeweils in Prozent des MSE des Fair-Modells ohne Noise-Modell.

Tabelle 25

Ergebnisse der Signifikanz-Tests der Unterschiede der MSE der Prognosen der verschiedenen Versionen des Fair-Modells und des "naiven" ARIMA-Modells

Post-Sample-Periode: 1973.1 - 1976.3

Modell mit höherem MSE		Modell mit niedrigerem MSE	
1. Abhängige Variable: CDF_t		Fair-Modell inkl. Fair-Modell ohne Noise-Modell	
Fair-Modell inkl. Noise-Modell			
Fair-Modell ohne Noise-Modell	n.s.		n.s.
ARIMA-Modell	n.s.		
2. Abhängige Variable: CAF_t			
Fair-Modell inkl. Noise-Modell			
Fair-Modell ohne Noise-Modell	n.s.		n.s.
ARIMA-Modell	s. .05		

Legende:

CDF_t , CAF_t s. Tabelle 33;

n.s.

nicht signifikant;

s. .05

signifikant (Irrtumswahrscheinlichkeit .05).

Modell inkl. Noise-Modell Autoausgaben mit einem signifikant niedrigeren MSE als das ARIMA-Modell prognostiziert. Dagegen sind die Unterschiede der MSE für Gebrauchsgüterausgaben nicht signifikant.

4622 Analyse auf der subjektiven Ebene

Die Analyse auf der subjektiven Ebene stützt sich auf das in den Zeichnungen 16 bis 23 vorgestellte Erscheinungsbild der Prognosen und Prognosefehler der verschiedenen Versionen des Fair-Modells und des ARIMA-Modells. In den Zeichnungen 20 bis 23 bedeuten negative (positive) Prognosefehler wieder eine Unterschätzung (Überschätzung) der tatsächlichen Werte.

1. Generell ist, wie z.B. den Zeichnungen 16 und 17 zu entnehmen ist, das Erscheinungsbild der tatsächlichen Werte geglätteter als das der bei der Evaluierung des Mueller-Modells verwendeten. Es ist zu bedenken, daß hier nominale Werte benutzt sind, denen aufgrund der in der betrachteten Post-Sample-Periode positiven Preissteigerungen ein trendähnliches Aussehen eigen ist. Starke Einbrüche der realen Werte erscheinen dadurch bei den nominalen Werten weniger ausgeprägt.

2. Das bessere Abschneiden des Fair-Modells inkl. Noise-Modell im Vergleich zum ARIMA-Modell, das in der Analyse der MSE festgestellt wurde, ist allein aufgrund der optischen Inspektion der Prognosen (vgl. Zeichnungen 16 und 17) nur schwer zu belegen. Immerhin scheint ab 1975.1 das Fair-Modell exaktere Prognosen als das ARIMA-Modell zu erzeugen.

Offensichtlich fehlt den ARIMA-Prognosen besonders für die

Umkehrpunkte der tatsächlichen Werte jede antizipative Eigenschaft. Da es sich hier jeweils um die Prognosen eines Random Walk-Modells, Prognosedistanz $l = 1$, handelt, ist dieses Erscheinungsbild zu erwarten. Die gleiche Kritik gilt jedoch auch für die Prognosen des Fair-Modells inkl. Noise-Modell, die - vgl. Zeichnungen 16 und 17 - jeweils eine Periode hinter den tatsächlichen Werten liegen. Bei Gebrauchsgüteraussgaben wird der negative Gipfel in 1974.4 sogar erst mit einer Verzögerung von zwei Perioden "prognostiziert".


Wiederum fällt die Ähnlichkeit der Erscheinungsbilder der Prognosen bzw. Prognosefehler des Fair-Modells inkl. Noise-Modell und des ARIMA-Modells auf. Besonders die Zeichnungen der Prognosefehler (20 und 21) vermitteln den Eindruck der Gleichförmigkeit sehr anschaulich. Wie schon oben kann für die Korrelation der Prognosefehler das Versäumnis beider Modelle verantwortlich gemacht werden, die wesentlichen in der Post-Sample-Periode wirksamen Einflußfaktoren zu erfassen.

3. Die Zeichnungen 20 und 21 geben auch Hinweise auf mögliche Fehlspezifikationen des Fair-Modells inkl. Noise-Modell und des ARIMA-Modells. Bei korrekter Spezifikation sollten die Prognosefehler jeweils dem Erscheinungsbild von weißem Rauschen ähneln. Auch ohne Signifikanz-Test läßt sich feststellen, daß die Prognosefehler offensichtlich positiv autokorreliert sind. Natürlich könnte dieses Erscheinungsbild der Prognosefehler auch auf eine Veränderung des in CDF_t und CAF_t wirksamen Erzeugungsmechanismus' rückführbar sein.

4. Aus den Zeichnungen 18, 19, 22 und 23 ist die Bedeutung des Noise-Modells für die Prognosegüte des Fair-Modells

PROGNOSEN

FAIR-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL



Legende:

$CDF = CDF_t$ Consumer durable goods expenditures in quarter t in billions of current dollars;

$PGFN = PGFN_t$ Prognose von CDF_t mithilfe des Fair-Modells inkl. Noise-Modell;


$PGFA = PGFA_t$ Prognose von CDF_t mithilfe des ARIMA-Modells.

CDF_t ist saisonal adjustiert.

Zeichnung 17

PROGNOSEN


FAJR-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL



Legende:

- CAF = CAF_t Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars;
- PAFN = PAFN_t Prognose von CAF_t mithilfe des FAJR-Modells inkl. Noise-Modell;
- PAFA = PAFA_t Prognose von CAF_t mithilfe des ARIMA-Modells.
- CAF_t ist saisonal adjustiert.

FAIR-MODELL INKL. NOISE-MODELL VS. OHNE NOISE-MODELL PROGNOSEN




Legende:

CDF = CDF_t Consumer durable goods expenditures in quarter t in billions of current dollars;
 PGFN = PGFN_t Prognose von CDF_t mithilfe des Fair-Modells inkl. Noise-Modell;
 PGFO = PGFO_t Prognose von CDF_t mithilfe des Fair-Modells ohne Noise-Modell.
 CDF_t ist saisonal adjustiert.

Zeichnung 19


FAIR-MODELL INKL. NOISE-MODELL VS. OHNE NOISE-MODELL PROGNOSEN



Legende:

- $CAF = CAF_t$ Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars;
 $PAFN - PAFN_t$ Prognose von CAF_t mithilfe des Fair-Modells inkl. Noise-Modell;
 $PAFO = PAFO_t$ Prognose von CAF_t mithilfe des Fair-Modells ohne Noise-Modell.
 CAF_t ist saisonal adjustiert.

PROGNOSEFEHLER FAIR-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL



Legende:


GFA = GFA_t Prognosefehler des ARIMA-Modells in bezug auf CDF_t;

GFN = GFN_t Prognosefehler des Fair-Modells inkl. Noise-Modell in bezug auf CDF_t;

CDF_t Consumer durable goods expenditures in quarter t in billions of current dollars.

CDF_t ist saisonal adjustiert.

PROGNOSEFEHLER FAIR-MODELL INKL. NOISE-MODELL VS. ARIMA-MODELL



Legende:


AFN = AFN_t Prognosefehler des Fair-Modells inkl. Noise-Modell in bezug auf CAF_t;

AFA = AFA_t Prognosefehler des ARIMA-Modells in bezug auf CAF_t;

CAF_t Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars.

CAF_t ist saisonal adjustiert.

FAIR-MODELL INKL. NOISE-MODELL VS. OHNE NOISE-MODELL PROGNOSEFEHLER



Legende:

GFN = GFN_t

GFO = GFO_t

CDF_t

CDF_t ist saisonal adjustiert.


Prognosefehler des Fair-Modells inkl. Noise-Modell in bezug auf CDF_t;

Prognosefehler des Fair-Modells ohne Noise-Modell in bezug auf CDF_t;

Consumer durable goods expenditures in quarter t in billions of current dollars.

Zeichung 23

PROGNOSEFEHLER FAIR-MODELL INKL. NOISE-MODELL VS. OHNE NOISE-MODELL



Legende:

AFN_t Prognosefehler des Fair-Modells inkl. Noise-Modell in bezug auf CAF_t ;

AFO_t Prognosefehler des Fair-Modells ohne Noise-Modell in bezug auf CAF_t ;

CAF_t Consumer expenditures on motor vehicles and parts in quarter t in billions of current dollars.

CAF_t ist saisonal adjustiert.

zu entnehmen. Die Prognosen des Fair-Modells ohne Noise-Modell zeichnen die tatsächliche Ausgabenentwicklung in nur sehr allgemeiner Form nach (vgl. Zeichnungen 18 und 19). Es werden jedoch immerhin die groben Kennzeichen der Kurven der tatsächlichen Werte - das verzögerte Ansteigen bis ca. 1975.1 und das darauffolgende, bis zum Ende der Post-Sample-Periode anhaltende stärkere Ansteigen - eingefangen.

Die bereits bei der Analyse der MSE festgestellte Überlegenheit des Fair-Modells inkl. Noise-Modell gegenüber dem Fair-Modell ohne Noise-Modell ist auch aus den Zeichnungen 20 und 21 deutlich herauslesbar. Fast durchgehend liegen die Prognosefehler des letztgenannten Modells über denen des Fair-Modells inkl. Noise-Modell, wobei die stärksten Unterschiede sich stets im Anschluß an negative bzw. positive Gipfel ergeben. Die Einbeziehung des Noise-Modells schärft offensichtlich die Sensibilität des Fair-Modells gegenüber anhaltenden Abweichungen der prognostizierten von den tatsächlichen Werten.

47 Zusammenfassung der Ergebnisse des ersten Teils der empirischen Analyse

1. Der ICS hat im Rahmen der von Mueller bzw. Fair empfohlenen Spezifikation in der gewählten Sample-Periode einen nur knapp signifikanten Erklärungswert für Gebrauchsgüter- und Autoausgaben, wenn ein Schätzverfahren verwendet ist, das der autokorrelativen Struktur der stochastischen Größe Rechnung trägt. Die dem widersprechenden Ergebnisse von Mueller (1963) (1963), Friend/Adams (1964), Suits/Sparks (1965), Maynes (1967), Burch/Stekler (1969), Juster (1969), Juster/Wachtel (1972a), Juster/Wachtel (1972b) und Adams/Klein (1972) müssen auf die Unzulänglichkeiten der dort verwendeten Schätzver-

fahren zurückgeführt werden.¹⁾

2. Die Post-Sample-Prognosen des Mueller-Modells inkl. Noise-Modell und des Fair-Modells inkl. Noise-Modell besitzen unter Zugrundelegung einer quadratischen Verlustfunktion und aufgrund ihres Erscheinungsbildes eine höhere Prognosegüte als "naive" Modelle aus der Klasse univariater ARIMA-Modelle, die mithilfe der iterativen Strategie von Box/Jenkins identifiziert und geschätzt sind. Dies kann als bemerkenswert bezeichnet werden, da ARIMA-Modelle in Post-Sample-Evaluierungen gegenüber ökonometrischen Modellen gute Ergebnisse vorweisen können.

3. Die Überlegenheit der Prognosen der den ICS einschließenden Modelle über die von ARIMA-Modellen hängt entscheidend von der Berücksichtigung des Noise-Modells, d.h. der autokorrelativen Struktur der Prognosefehler ab. Ohne Noise-Modell ist die Prognosegüte des Mueller-Modells bzw. des Fair-Modells schlechter als die der ARIMA-Modelle.²⁾ Das Noise-Modell sorgt insbesondere dafür, die Prognosen bei größeren Abweichungen wieder an die tatsächlichen Werte heranzuführen.

Dieses Ergebnis bestätigt die Kritik an der Nichtberücksichtigung des Noise-Modells bei der Erzeugung der Post-Sample-Prognosen in den Untersuchungen von Burch/Stekler (1969),

- 1) Die Vergleichbarkeit mit den Ergebnissen der aufgezählten Autoren ist dadurch etwas eingeschränkt, daß nicht immer die gleichen Spezifikationen wie die hier verwendeten (Mueller-Modell, Fair-Modell) zugrundeliegen. Die Geringfügigkeit der Unterschiede läßt die geäußerte Kritik jedoch vertretbar erscheinen.
- 2) Beim Mueller-Modell gilt diese Aussage nur im Vergleich zu den Prognosen des ARIMA-Modells für Prognosedistanz $l = 2$. Das ARIMA-Modell für Prognosedistanz $l = 3$ erzeugt unter dem Kriterium einer quadratischen Verlustfunktion Prognosen mit geringerer Prognosegüte als das Mueller-Modell ohne Noise-Modell. Das Erscheinungsbild der Prognosen des Mueller-Modells ohne Noise-Modell weist jedoch eine wesentlich geringere Sensibilität gegenüber der Entwicklung der tatsächlichen Werte als das ARIMA-Modell für Prognosedistanz $l = 3$ auf (vgl. Zeichnungen 6,7,8 und 9).

Juster (1969), Hymans (1970), Fair (1971) und Adams/Klein (1972).

4. Die iterative Strategie von Box/Jenkins ermöglicht die Identifikation und Schätzung univariater ARIMA-Modelle, die offensichtlich eher als die von Burch/Stekler (1969) und Juster (1969) verwendeten "naiven" Modelle die Zeitreihennatur der zu prognostizierenden Variablen erfassen. Sie stellen damit einen geeigneteren Maßstab zur Beurteilung der Prognosegüte von Modellen, die den ICS einschließen, dar.

5. Es ist festzuhalten, daß die Post-Sample-Prognosen der den ICS einschließenden Modelle ohne Einbeziehung des Noise-Modells eine - wenn auch gering ausgeprägte - Sensibilität gegenüber der Entwicklung der tatsächlichen Ausgabenwerte aufweisen, wie den Zeichnungen 8, 9, 10, 11, 18 und 19 zu entnehmen ist.

6. Es gibt Anzeichen für eine höhere Nützlichkeit des ICS bei der Post-Sample-Prognose von Autoausgaben als bei der von Gebrauchsgüterausgaben.

7. Im besonderen die Analyse der Zeichnungen 4, 5, 6, 7, 16 und 17 deckt auf, daß offensichtlich keines der berücksichtigten Modelle - weder die den ICS einschließenden Modelle noch die "naiven" Modelle - die Faktoren, die für den starken Einbruch der realen Ausgabenwerte ab 1973.1 verantwortlich sind, repräsentiert. Generell scheint in der gewählten Post-Sample-Periode die antizipative Fähigkeit aller Modelle nur in geringem Maße entwickelt zu sein. Die Prognosen vollziehen den Verlauf der tatsächlichen Werte eher nach als daß sie

ihn voraussagten. Dies erklärt auch die Ähnlichkeit der Prognosefehler aller Modelle sowie das bereits optisch erkennbare Auftreten von Autokorrelation in den Reihen der Prognosefehler derjenigen Modelle (des Fair-Modells inkl. Noise-Modell und seines "naiven" Alternativmodells), deren Prognosefehler ein weißem Rauschen ähnliches Erscheinungsbild aufweisen sollten. Da die autokorrelative Struktur der Prognosefehler als ein Kriterium der Modelladäquanz gelten kann, ergibt sich hieraus ein Hinweis auf mögliche Misspezifikationen.

5 Zweiter Teil der empirischen Analyse: Spezifikation der Beziehungen des ICS zu ökonomischen Variablen

51 Der zeitreihentheoretische Ansatz als Grundlage der Analyse

1. Im zweiten Teil der empirischen Analyse wird der Spezifikation von Modellen, die den ICS einschließen, Aufmerksamkeit geschenkt. Der verwendete Ansatz basiert auf den Vorschlägen von Box/Jenkins¹⁾ und Granger/Newbold²⁾. Er greift in systematischer Weise auf die in den Daten selbst enthaltene Information zurück. Für das Verständnis dieser Konzeption ist eine kurze Diskussion der ihr zugrundeliegenden Vorstellungen angebracht.

2. In der Literatur findet sich die Unterscheidung zwischen dem "ökonometrischen" und dem "zeitreihentheoretischen" Ansatz zur Modell-Spezifikation.³⁾

Der ökonometrische Ansatz bezieht sich im allgemeinen auf ein System interdependenter Gleichungen in der Form eines ökonometrischen Modells. Kennzeichnend für diesen Ansatz ist der Rückgriff auf die ökonomische Theorie zur Spezifikation der strukturellen Form eines ökonometrischen Modells. Die ökonomische Theorie liefert den grundsätzlichen Rahmen, in dem die Analyse stattfindet; die Daten dienen hier nur dazu, die von der Theorie vorgegebene Spezifikation zu testen und Schätzungen der Parameter zu erstellen.

1) Vgl. Box/Jenkins (1976), S. 337 ff.

2) Vgl. Granger/Newbold (1977), S. 215 ff.

3) Die Bezeichnungen sind in Anlehnung an Granger/Newbold gewählt: "The analysis of economic data has ... been approached from two different philosophies, that proposed by time series analysts and the more classical econometric approach". Granger/Newbold (1977), S. xi. In der Literatur finden sich auch andere Bezeichnungen für den gleichen Zusammenhang. S. z.B. Montgomery/Johnson (1976), S. 7: "Two basic types of models ... : time series models and causal models"; Klein (1977), S. 772: "It has often been argued that there are two kinds of models - a pure forecasting model and a structural model". Koopmans bezeichnet den ökonometrischen Ansatz als "Newton stage" und den zeitreihentheoretischen als "Kepler stage". Vgl. Koopmans (1947), S. 161.

3. Als Bezugspunkt des zeitreihentheoretischen Ansatzes kann das univariate Zeitreihenmodell genannt werden, dessen Prognosen ausschließlich auf den Werten der zu prognostizierenden Variablen selbst beruhen. Kennzeichnend ist hier die Nichtverwendung von Einsichten der ökonomischen Theorie bei der Spezifikation von Modellen;¹⁾ ausschließlich die aus der Betrachtung der Daten sich ergebenden Hinweise werden berücksichtigt. In diesem Sinne ist die iterative Strategie von Box/Jenkins zur Identifikation und Schätzung univariater ARIMA- bzw. ARMA-Modelle als zeitreihentheoretischer Ansatz zu bezeichnen.²⁾

4. Die Überlegenheit des ökonometrischen oder des zeitreihentheoretischen Ansatzes wird auch nach seiner Fähigkeit beurteilt werden müssen, das Verhalten ökonomischer Reihen zu prognostizieren.³⁾ Obwohl die Überlegenheit des ökonometrischen Ansatzes zur Prognose häufig behauptet

-
- 1) "The toolkit of the theoretical economist is deliberately spurned". Koopmans (1947), S. 163.
 - 2) Als Beispiele für den ökonometrischen und zeitreihentheoretischen Ansatz mögen die im ersten empirischen Teil verwendeten Modelle dienen. Der ökonometrische Ansatz ist bei der Spezifikation des Mueller- bzw. Fair-Modells zumindestens mit berücksichtigt, während die Spezifikation der "naiven" Modelle dem zeitreihentheoretischen Ansatz folgend rein datengesteuert ist. Das als lineares Regressionsmodell spezifizierte Mueller-Modell kann hier als Grenzfall eines ökonometrischen Modells angesehen werden.
 - 3) Ökonometrische Modelle können auch anderen Zwecken dienen, wie z.B. der Simulation der Konsequenzen unterschiedlicher Handlungsalternativen oder dem Test ökonomischer Theorien. Zu den Anwendungsmöglichkeiten ökonometrischer Modelle vgl. Suits (1962), Howrey et al. (1974). Ihre Fähigkeit zur Prognose wird jedoch weitgehend ihre Eignung für andere Zwecke bestimmen. S. auch Granger/Newbold (1977), S. 289: "... we would be extremely dubious about the use of a model for any of this other purposes if it were incapable of forecasting well". Klein (1977), S. 770: "Forecast accuracy is the first application that policy makers turn to; it is essential for establishing credibility in a model and it is a severe testing ground for a model ...".

wird,¹⁾ liegen keine überzeugenden Nachweise seiner besseren Prognosegüte vor.²⁾

Nach Granger/Newbold ist hierfür die bei der Spezifikation dynamischer Modelle auftretende Problematik verantwortlich: "... although economic theory frequently postulates the existence of time lags in relationships, it is rarely sufficient specific to be of much help in determining their algebraic structure. A final, and to our mind vital, point concerns the specification of an appropriate time series structure for the errors from the individual equations of econometric models. We have occasionally heard it suggested that, even here, economic theory can be used to suggest an appropriate structure. However, the arguments advanced in favor of such an assertion have

- 1) S. z.B. Koopmans (1947), S. 162: "Fuller utilization of the concepts and hypotheses of economic theory ... as a part of the process of observation and measurement promises to be a shorter road, perhaps even the only road to the understanding of cyclical fluctuations". Spencer et al. (1965), S. 10 f.: "... further research will probably bear out that the traditional methods of time series analysis may provide at best a mere description of a set of data and at worst an enormous waste of time, effort and expense in arriving at what amounts to nothing more than an illusory explanation of systematic movements". Klein (1977), S. 772: "There are fundamental reasons why the attempts to construct purely forecasting models are likely to result in serious failures ...".
- 2) Der in Tabelle 3 vorgenommene Vergleich zwischen der Prognosegüte ökonometrischer Modelle und der univariater ARIMA-Modelle mag hierfür als Illustration dienen. S. auch Stekler (1970), S. 56: "... econometric models have not been entirely successful in forecasting economic activity". Fair (1971), S. 3: "Unfortunately, the development of large-scale models has not yet reached a point in which confidence can be placed in their forecasting ability". Granger/Newbold (1977), S. 298: "Given the relatively poor predictive performance frequently observed in econometric models, the reader may be tempted to wonder just how econometric forecasters manage to stay in business ... the results achieved in particular studies by some econometric models are on occasions so poor as to lead to profound skepticism about the value of further forecasts obtained from such sources". Ando/Palash (1977), S. 784: "Large scale econometric models often come under severe criticism because economic forecasts produced by them can be quite inaccurate ...".

always been less than convincing, and accordingly we cannot accept it as realistic ... it must be assumed, a priori, that the error structures of such models is misspecified".¹⁾

Die Aussage von Granger/Newbold trifft im besonderen Maße auf die Theorie der "Psychological Economics" zu, die zur Spezifikation von Lag-Verteilungen in Modellen zur Prognose diskretionärer Konsumausgaben oder der als "intervening variables" fungierenden psychologischen Konzepte keine Informationen erteilt.

5. Aus diesen Gründen erscheint die Verwendung des zeitreihentheoretischen Ansatzes nicht nur zur Bildung univariater Prognosemodelle, sondern auch zur Spezifikation von Modellen, die das zwischen Zeitreihen existierende Kausalmuster beschreiben, erwägenswert. Anstelle der ökonomischen Theorie wird die Empirie selbst herangezogen, um Hinweise auf die Natur der bestehenden Beziehungen zu gewinnen.²⁾

Die Eignung des zeitreihentheoretischen Ansatzes zur Spezifikation von Modellen, die die Beziehung des ICS zu ökonomischen Variablen beschreiben, beruht auf

- der Analogie zwischen ökonometrischen Modellen und Vektor-ARMA-Prozessen;
- der Verfügbarkeit über eine von Box/Jenkins und Granger/Newbold empfohlene iterative Strategie zur Identifikation und Schätzung von Repräsentationsformen bivariater ARMA-Modelle.

1) Granger/Newbold (1977), S. 199. S. auch Prothero/Wallis (1976), S. 469: "... economic theory generally has little to say about the dynamics of the relationship, and the specification of the detailed structure ... is usually data-based in a very rudimentary fashion".

2) "The data themselves are permitted, insofar as feasible, to suggest, at least in general terms, the patterns of interrelationships that do or do not exist". Pierce (1977), S. 11.

52 Die Analogie zwischen ökonometrischen Modellen und Vektor-ARMA-Prozessen

1. In Abschnitt 4221 ist die Beziehung zwischen univariaten ARMA-Prozessen und ökonometrischen Modellen aufgezeigt, wobei als Ausgangspunkt der Darstellung die strukturelle Form ökonometrischer Modelle diente. Die folgende Darstellung bezweckt eine Beschreibung der Zusammenhänge zwischen Vektor-ARMA-Prozessen und ökonometrischen Modellen. Ausgangspunkt ist hier der Vektor-ARMA-Prozeß $\underline{Z}$, dessen parametrische Repräsentation in Matrix-Notation laute:¹⁾

$$(5.1) \quad \underline{H(B)}\underline{Z} = \underline{F(B)}\underline{E}$$

wobei

$$\underline{Z}' = \begin{bmatrix} \underline{Z}_1 & \underline{Z}_2 & \dots & \underline{Z}_m \end{bmatrix}$$

$$\underline{Z}'_1 = \begin{bmatrix} Z_{11} & Z_{12} & \dots & Z_{1T} \end{bmatrix}$$

$$\underline{E}' = \begin{bmatrix} \underline{E}_1 & \underline{E}_2 & \dots & \underline{E}_m \end{bmatrix}$$

$$\underline{E}'_1 = \begin{bmatrix} E_{11} & E_{12} & \dots & E_{1T} \end{bmatrix}$$

$$l = 1, \dots, m$$

$\underline{Z}$ ist die Matrix der m Prozesse $\underline{Z}_1$, $\underline{E}$ ist die Matrix der stochastischen Größen, wobei $\underline{E}_1$ weißes Rauschen ist, und $\underline{H(B)}$ und $\underline{F(B)}$ sind Matrizen von Operatorpolynomen. Es ist angenommen, alle Wurzeln der polynomischen Gleichungen

$$(5.2) \quad \left| \underline{H(B)} \right| = 0$$

$$\left| \underline{F(B)} \right| = 0$$

1) Vgl. zum folgenden Zellner/Palm (1974), S. 18 - 20, Granger/Newbold (1977), S. 217 f., Prothero/Wallis (1976), S. 469 f.

lügen außerhalb des Einheitskreises. Ferner gelte:

$$E(\underline{Z}) = \underline{0}$$

wobei $\underline{0}$ eine Nullmatrix ist.

Die Analogie des Vektor-ARMA-Prozesses in Gleichung (5.1) zu einem ökonometrischen Modell ergibt sich unter Berücksichtigung von a priori-Information in bezug auf das Abhängigkeitsverhältnis der Prozesse Z_{1t} . Hierzu sei (5.1) in folgender Weise dargestellt:

$$(5.3) \quad \begin{bmatrix} \underline{H}_{11}(B) & \underline{H}_{12}(B) \\ \underline{H}_{21}(B) & \underline{H}_{22}(B) \end{bmatrix} \begin{bmatrix} \underline{Y} \\ \underline{X} \end{bmatrix} = \begin{bmatrix} \underline{F}_{11}(B) & \underline{F}_{12}(B) \\ \underline{F}_{21}(B) & \underline{F}_{22}(B) \end{bmatrix} \begin{bmatrix} \underline{E}_Y \\ \underline{E}_X \end{bmatrix}$$

wobei

$$\begin{bmatrix} \underline{Y} \\ \underline{X} \end{bmatrix} = \underline{Z}$$

$$\begin{bmatrix} \underline{E}_Y \\ \underline{E}_X \end{bmatrix} = \underline{E}$$

$$\begin{bmatrix} \underline{H}_{11}(B) & \underline{H}_{12}(B) \\ \underline{H}_{21}(B) & \underline{H}_{22}(B) \end{bmatrix} = \underline{H}(B)$$

$$\begin{bmatrix} \underline{F}_{11}(B) & \underline{F}_{12}(B) \\ \underline{F}_{21}(B) & \underline{F}_{22}(B) \end{bmatrix} = \underline{F}(B)$$

Es sei angenommen, $\underline{Y}$ repräsentiere die endogenen und $\underline{X}$ die exogenen Variablen. Aufgrund dieser Annahme folgt:¹⁾

$$(5.4) \quad \underline{H}_{21}(\underline{B}) = \underline{0}$$

$$(5.5) \quad \underline{F}_{21}(\underline{B}) = \underline{0}$$

$$(5.6) \quad \underline{F}_{12}(\underline{B}) = \underline{0}$$

Die Elemente in $\underline{E}_Y$ haben somit keinen Einfluß auf die in $\underline{X}$, und die Elemente in $\underline{E}_X$ beeinflussen die in $\underline{Y}$ nur durch die in $\underline{X}$. Gleichung (5.3) kann somit als strukturelle Form eines ökonometrischen Modells bezeichnet werden.²⁾ Aus ihr lassen sich die reduzierte und finale Form³⁾ eines ökonometrischen Modells ableiten. Für die weiteren Ausführungen ist die finale Form von besonderem Interesse, die sich aus (5.3), (5.4), (5.5) und (5.6) ergibt:

$$(5.7) \quad \underline{Y} = - \underline{H}_{11}^{-1}(\underline{B}) \underline{H}_{12}(\underline{B}) \underline{X} + \underline{H}_{11}^{-1}(\underline{B}) \underline{F}_{11}(\underline{B}) \underline{E}_Y$$

1) Vgl. zum folgenden Zellner/Palm (1974), S. 18 ff.

2) Der in Gleichung (5.3) beschriebene Erzeugungsmechanismus der exogenen Variablen ist im allgemeinen nicht Bestandteil ökonometrischer Modelle.

3) Zur finalen Form vgl. Theil/Boot (1962), Klein (1968), S. 16.

Hier ist angenommen, alle Wurzeln der polynomischen Gleichung

$$(5.8) \quad \left| \underline{H}_{11}(B) \right| = 0$$

lügen außerhalb des Einheitskreises. Schließlich kann aus der finalen Form die autoregressive finale Form¹⁾ gewonnen werden:

$$(5.9) \quad \left| \underline{H}_{11}(B) \right| \underline{Y} = - \underline{H}_{11}^*(B) \underline{H}_{12}(B) \underline{X} + \underline{H}_{11}^*(B) \underline{F}_{11}(B) \underline{E}_Y$$

Hierbei ist $\underline{H}_{11}^*(B)$ die Matrix der Adjunkten von $\underline{H}_{11}(B)$. Bei der Herleitung von (5.9) aus (5.7) ist zu bedenken, daß²⁾

$$\underline{H}_{11}^{-1}(B) = \frac{\underline{H}_{11}^*(B)}{\left| \underline{H}_{11}(B) \right|}$$

2. Die vorausgegangene Ableitung erläuterte den Zusammenhang zwischen den Repräsentationsformen von Vektor-ARMA-Prozessen und ökonometrischen Modellen. Im weiteren sind die wesentlichen Elemente einer iterativen Strategie vorgestellt, die über die Identifikation und Schätzung von Vektor-ARMA-Prozessen eine Modellierung von Beziehungen zwischen Variablen ermöglichen soll. Die identifizierten und geschätzten Modelle können dann zugleich als Repräsentationsformen ökonometrischer Modelle verstanden werden.

53 Die iterative Strategie von Box/Jenkins und Granger/Newbold zur Identifikation und Schätzung der Transferfunktion-Form bivariater ARMA-Modelle

531 Einleitung

1. Die Grundlagen der iterativen Strategie zur Identifikation und Schätzung bivariater ARMA-Modelle sind von Box/Jenkins³⁾

1) Vgl. hierzu Zellner/Palm (1974), S. 21

2) Vgl. Granger/Newbold (1977), S. 217.

3) Vgl. Box/Jenkins (1976), S. 335 ff.

entwickelt; der Beitrag von Granger/Newbold¹⁾ besteht in der Integration der Transformation zu weißem Rauschen. Da eine kohärente Darstellung dieser Strategie in der Literatur nicht existiert - Box/Jenkins verwenden ein anderes Transformationsverfahren und Granger/Newbold gehen nicht detailliert auf den Ansatz von Box/Jenkins ein -, ²⁾ seien die wesentlichen Elemente hier kurz beschrieben.

Wie bei Box/Jenkins und Granger/Newbold beschränkt sich die Darstellung dabei auf bivariate Modelle, weil die methodischen und technischen Probleme der Identifikation und Schätzung von Vektor-ARMA-Modellen zu umfangreich werden, wenn mehr als zwei Serien zu betrachten sind.³⁾

2. Die Bezugnahme auf Box/Jenkins läßt eine Annäherung der Terminologie geboten erscheinen. Es sei daher die "Transferfunktion-Form" des bivariaten ARMA-Prozesses eingeführt:

$$(5.10) \quad Y_t = A_Y(B)B_Y^{-1}(B)X_t + C_Y(B)D_Y^{-1}(B)E_{Yt} = V_Y(B)X_t + G_Y(B)E_{Yt}$$

$$X_t = C_X(B)D_X^{-1}(B)E_{Xt} = G_X(B)E_{Xt}$$

wobei sich die Beziehung zu der in Gleichung (5.3) verwendeten Notation wie folgt ergibt:⁴⁾

- 1) Vgl. Granger/Newbold (1977), S. 215 ff.
- 2) Beispiele für die Anwendung der iterativen Strategie finden sich bei Cramer/Miller (1976), Haugh/Box (1977), Pierce (1977).
- 3) S. z.B. Granger/Newbold (1977), S. 230: "... the methodological difficulties are such that the construction of a general m-variable time series model, from series of length likely to occur in practice, is prohibitively difficult unless m is very small". Ibid., S. 300: "The appropriate methodology is by no means simple, even in the two-variable case, and a practical general multivariate time series procedure of proven value still awaits development".
- 4) Auf Unterstreichungen, die die Matrix-Notation anzeigen, ist hier verzichtet, da die Operatorpolynome $A_Y(B)$, ..., $H_{12}(B)$, etc., im bivariaten Fall keine Matrizen sind.

$$(5.11) \quad A_Y(B) = -H_{12}(B)$$

$$B_Y(B) = H_{11}(B)$$

$$C_Y(B) = F_{11}(B)$$

$$D_Y(B) = H_{11}(B)$$

$$C_X(B) = F_{22}(B)$$

$$D_X(B) = H_{22}(B)$$

Ferner gilt:

$$(5.12) \quad \begin{aligned} V_Y(B) &= A_Y(B)B_Y^{-1}(B) = \sum_{i=0}^{\infty} v_i B^i X_t \\ G_Y(B) &= C_Y(B)D_Y^{-1}(B) = \sum_{i=0}^{\infty} g_{Yi} B^i E_{Yt} \quad \text{mit } g_{Y0} = 1 \\ G_X(B) &= C_X(B)D_X^{-1}(B) = \sum_{i=0}^{\infty} g_{Xi} B^i E_{Yt} \quad \text{mit } g_{X0} = 1 \end{aligned}$$

Natürlich ist $B_Y(B) = D_Y(B)$. Um die Analogie zu Box/Jenkins zu wahren, ist die Gleichheit der Operatorpolynome $B_Y(B)$ und $D_Y(B)$ in der Transferfunktion-Form (5.10) nicht explizit gemacht.¹⁾ Wie der Vergleich mit Gleichung (5.7) zeigt, entspricht die Transferfunktion-Form für Y_t der finalen Form.

Im weiteren wird $V_Y(B)$ ($= A_Y(B)B_Y^{-1}(B)$) als "Transferfunktion"²⁾ und $G_Y(B)$ ($= C_Y(B)D_Y^{-1}(B)$) bzw. $G_X(B)$ ($= C_X(B)D_X^{-1}(B)$) als "Noise-Modell"³⁾ bezeichnet.

1) Es ist auch deswegen von einer Gleichsetzung von $B_Y(B)$ und $D_Y(B)$ abgesehen, weil bei der Anwendung der iterativen Strategie doch häufig mit Approximierungen gearbeitet werden muß, deren Ergebnisse nicht exakt den von der Theorie vorgezeichneten entsprechen müssen.

2) Vgl. Box/Jenkins (1976), S. 338.

3) Vgl. ibid., S. 362.

3. Gleichung (5.10) unterstellt einen kausalen Einfluß von X auf Y, schließt also die Existenz einer Feedback-Beziehung - X beeinflusst Y und Y beeinflusst X - ebenso wie die simultanen Beziehungen aus.¹⁾ Vor der Anwendung der iterativen Strategie von Box/Jenkins und Granger/Newbold ist somit die Art der zwischen den Reihen existierenden Kausalität zu prüfen. Diese Prüfung wird hier als "Kausalitätsanalyse" bezeichnet.

532 Kausalitätsanalyse

5321 Die zugrundeliegende Kausalitäts-Konzeption: Granger-Kausalität

1. Der hier vertretene Kausalitätsbegriff basiert auf der von Granger empfohlenen Konzeption. Eine Darstellung der wesentlichen Elemente dieser Konzeption ist wegen ihrer Bedeutung für die weitere Analyse notwendig.

2. Grangers Kausalitäts-Konzeption (im folgenden als "Granger-Kausalität" bezeichnet) bezieht sich auf die Prognostizierbarkeit stochastischer Prozesse und basiert auf zwei Prämissen:²⁾

- Die Zukunft kann nicht die Gegenwart oder die Vergangenheit beeinflussen.
- Es ist nur sinnvoll, Kausalität für stochastische

1) Die Identifikation und Schätzung eines bivariaten Modells wird durch die Existenz von Feedback- und simultanen Beziehungen erheblich kompliziert. Vgl. hierzu Granger/Newbold (1977), S. 222 ff. und S. 246 ff.

2) Vgl. Granger/Newbold (1977), S. 224 ff.

Prozesse zu diskutieren. Es ist nicht möglich, Kausalität zwischen deterministischen Prozessen aufzudecken.

Eine formale Definition von Granger-Kausalität läßt sich wie folgt geben. Es seien:

$Y_t; X_t$ Stationäre stochastische Prozesse; ¹⁾

$\bar{Y}_t = \{ Y_{t-k}, k = 0, 1, \dots, \infty \};$

$\bar{Y}_t = \{ Y_{t-k}, k = 1, 2, \dots, \infty \};$

$I_{\bar{Y}_t}$ Informations-Menge, bestehend aus $\bar{Y}_t$;

$I_{\bar{Y}_t, \bar{X}_t}$ Informations-Menge, bestehend aus $\bar{Y}_t$ und $\bar{X}_t$;

$P(Y_t | I_{\bar{Y}_t})$ Optimale lineare Prognose von Y_t , basierend auf $I_{\bar{Y}_t}$; ^{2), 3)}

$$(5.13) \quad E_t(Y_t | I_{\bar{Y}_t}) = Y_t - P(Y_t | I_{\bar{Y}_t});$$

$$(5.14) \quad \sigma^2(Y_t | I_{\bar{Y}_t}) = E(E_t(Y_t | I_{\bar{Y}_t}))^2.$$

Definition: Einfache Granger-Kausalität

Wenn

$$(5.15) \quad \sigma^2(Y_t | I_{\bar{Y}_t}) > \sigma^2(Y_t | I_{\bar{Y}_t, \bar{X}_t})$$

- 1) Stationarität ist keine notwendige Bedingung, aber sie erleichtert Tests: "The definitions of causality ... are easily generalized to the non-stationary case by the use of nonstationary predictors, but the effect on the tests involved is likely to prove more difficult to determine". Granger/Hatanaka (1964), S. 125.
- 2) Linearität ist ebenfalls keine notwendige Bedingung. Die Ausweitung auf nichtlineare Beziehungen wirft jedoch gewisse Probleme auf: "Unless a specific theory is available to suggest the form of nonlinearity involved, this representation is too general to be usable. One is forced to consider a specific form for the prediction, and that most used, due to simplicity, is the linear form". Granger/Newbold (1977), S. 226.
- 3) Entsprechende Definition für $P(Y_t | I_{\bar{Y}_t, \bar{X}_t})$, $P(X_t | I_{\bar{X}_t})$, $P(X_t | I_{\bar{X}_t, \bar{Y}_t})$ und $P(Y_t | I_{\bar{Y}_t, \bar{X}_t})$.

so ist Y_t einfach Granger-kausal von X_t beeinflusst. Y_t läßt sich besser mit einer Informations-Menge prognostizieren, die $\bar{Y}_t$ und $\bar{X}_t$ umfaßt, als mit einer Informations-Menge, die nur $\bar{Y}_t$ umfaßt.

Definition: Granger-Feedback

Wenn

$$(5.16) \quad \sigma^2(Y_t | I_{\bar{Y}_t}) > \sigma^2(Y_t | I_{\bar{Y}_t}, \bar{X}_t)$$

$$\sigma^2(X_t | I_{\bar{X}_t}) > \sigma^2(X_t | I_{\bar{X}_t}, \bar{Y}_t)$$

so liegt Granger-Feedback vor. Y_t kann also besser mit $I_{\bar{Y}_t}, \bar{X}_t$ prognostiziert werden als mit $I_{\bar{Y}_t}$, und X_t kann besser mit $I_{\bar{X}_t}, \bar{Y}_t$ prognostiziert werden als mit $I_{\bar{X}_t}$.

Definition: Gleichzeitige Granger-Kausalität

Wenn

$$(5.17) \quad \sigma^2(Y_t | I_{\bar{Y}_t}, \bar{X}_t) > \sigma^2(Y_t | I_{\bar{Y}_t}, \bar{\bar{X}}_t)$$

so liegt gleichzeitige Granger-Kausalität vor. Y_t kann besser mithilfe einer Informations-Menge prognostiziert werden, die $\bar{X}_t$ und $\bar{Y}_t$ umfaßt, als mithilfe einer Informations-Menge, die nur $\bar{Y}_t$ und $\bar{\bar{X}}_t$ enthält.

Voraussetzung für die Statuierung von Granger-Kausalität ist also die Existenz nichtredundanter Information: nur wenn ein stochastischer Prozeß Information zur Prognose eines anderen stochastischen Prozesses enthält, die nicht auch in dem zu

prognostizierenden Prozeß selbst enthalten ist, kann von Granger-Kausalität gesprochen werden.¹⁾

3. Die Bedeutung der Kausalitäts-Konzeption von Granger ergibt sich aus den weiteren Ausführungen.

5322 Das Kreuzkorrelogramm als Instrument der Kausalitätsanalyse

1. Als Grundlage der Kausalitätsanalyse dient die Kreuzkorrelation, die in Gleichung (4.39) definiert ist.

Die Kreuzkorrelation $r_{YX}(k)$ zweier stationärer stochastischer Prozesse Y_t und X_t ist nur von der Zeitdifferenz k und nicht von der absoluten Zeit t abhängig. Anders als die Autokorrelationen liegen die Kreuzkorrelationen nicht symmetrisch um $k = 0$; d.h. es gilt im allgemeinen $r_{YX}(k) \neq r_{YX}(-k)$. Da jedoch $r_{YX}(k) = r_{XY}(-k)$, müssen nur die Kreuzkorrelationen $r_{YX}(k)$ für alle k berücksichtigt werden.²⁾

2. Eine konsistente Schätzung der theoretischen Kreuzkorrelation $r_{YX}(k)$ ist die in einer Realisation von T Beobachtungen y_t und x_t gemessene Kreuzkorrelation $r_{yx}(k)$, die definiert ist als:³⁾

$$(5.18) \quad r_{yx}(k) = \frac{\sum_{t=1+k}^T (y_t - \bar{y}_t)(x_{t-k} - \bar{x}_t)}{(\sum_{t=1}^T (y_t - \bar{y}_t)^2 \sum_{t=1}^T (x_t - \bar{x}_t)^2)^{1/2}}$$

1) Vgl. Granger (1969), S. 430, Pierce (1977), S. 12, Pierce/Haugh (1977), S. 265 f. Aus dieser Interpretation wird ersichtlich, warum die Konzeption der Granger-Kausalität nicht auf deterministische Reihen anwendbar ist: "... a purely deterministic series, that is, a series which can be predicted exactly from its past terms such as a nonstochastic series, cannot be said to have any causal influence other than its own past". Granger (1969), S. 430.

2) Wie bereits in Abschnitt 421 betont, wird hier der Begriff Stationarität im Sinne von "schwach stationär" verstanden.

3) Vgl. Jenkins/Watts (1968), S. 336.

$\bar{y}_t$ bzw. $\bar{x}_t$ sind die Mittelwerte der y_t bzw. x_t .

3. Es liegt nahe, die Kreuzkorrelationen $r_{YX}(k)$ zum Test auf die Existenz von Granger-Kausalität heranzuziehen. Falls z.B. $r_{YX}(k) \neq 0$ für mindestens ein $k > 0$, aber $r_{YX}(k) = 0$ für $k \leq 0$, so könnte von einer Prognostizierbarkeit von Y_t durch verzögerte Werte von X_t gesprochen werden.

4. In der Literatur findet sich jedoch der Vorschlag, bei Vorliegen autokorrelierter Prozesse bzw. der Realisationen autokorrelierter Prozesse vor Berechnung der Kreuzkorrelationen zunächst eine Transformation jeder einzelnen Serie zu weißem Rauschen vorzunehmen: "If a test is required for non-zero correlation between two time series, a filtering operation should be carried out on the two series ... to convert them to white noise before computing the cross-covariance function"¹⁾; "For premathematical statistical investigations of the specification of the models to be fitted, it may be essential to first model each component by itself"²⁾; "Using standard univariate time series methods, first fit a mixed autoregressive/moving-average model to each series separately"³⁾ ... In fitting individual models to Y_t , X_t , we are essentially "prewhitening" each series, i. e., we are removing the autocorrelation structure"⁴⁾; " ... rather than look at the cross correlations between $Y_{1,t}$ and $Y_{2,t}$, one should first build univariate models ... and examine the cross correlations between the individual white noise residuals (or innovation) series ... "⁵⁾, ⁶⁾.

1) Jenkins/Watts (1969), S. 340.

2) Parzen (1969), S. 389.

3) Priestley (1971), S. 307.

4) Ibid., S. 309.

5) Granger/Newbold (1977), S. 232.

6) Vgl. auch in diesem Sinne Granger/Newbold (1976), Haugh (1976), Haugh/Box (1977), Pierce/Haugh (1977), Pierce (1977).

Der Vorschlag der Transformation zu weißem Rauschen gründet sich auf zwei Aspekte:

- die Eigenschaften der Erzeugungsfunktion der theoretischen Kreuzkorrelationen $r_{YX}(k)$ bzw. Kreuzkovarianzen $c_{YX}(k)$;
- die statistischen Eigenschaften der geschätzten Kreuzkorrelationen $r_{yx}(k)$.

5323 Die Transformation zu weißem Rauschen vor Berechnung des Kreuzkorrelogramms

1. Die Probleme, die Autokorrelation für die Interpretation des Kreuzkorrelogramms aufwirft, lassen sich am Beispiel der Transferfunktion-Form (vgl. Gleichung (5.10)) des bivariaten ARMA-Prozesses demonstrieren.¹⁾

Es läßt sich nachweisen,²⁾ daß aus (5.10) folgt:

$$(5.19) \quad c_{YY}(z) = V_Y(z) c_{XX}(z)$$

- 1) Vgl. zum folgenden Granger/Newbold (1977), S. 231 f.
Um die Vergleichbarkeit mit der Darstellung bei Granger/Newbold zu wahren, beziehen sich die folgenden Ausführungen auf die Kreuzkovarianzen $c_{YX}(k)$ anstelle der Kreuzkorrelationen $r_{YX}(k)$, wobei

$$c_{YX}(k) = r_{YX}(k) \sigma_Y \sigma_X$$

Wegen der engen Verknüpfung der $c_{YX}(k)$ und $r_{YX}(k)$ ist damit kein Verlust an Aussagekraft verbunden.

- 2) Da in (5.10) gilt:

$$E(X_t E_{Y,t-k}) = 0 \quad \text{alle } k$$

folgt:

$$E((Y_t - V_Y(B)X_t)(X_{t-k})) = 0 \quad \text{alle } k$$

oder:

$$c_{YX}(k) - \sum_{i=0}^{\infty} v_{Yi} c_{XX}(k-i) = 0 \quad \text{alle } k$$

Nach Summierung über k und Multiplikation mit z^k ergibt sich:

$$\sum_{k=-\infty}^{\infty} c_{YX}(k) z^k - \sum_{i=0}^{\infty} \sum_{k=-\infty}^{\infty} v_{Yi} c_{XX}(k-i) z^k = 0$$

oder:

$$c_{YX}(z) = V_Y(z) c_{XX}(z)$$

Die v_{Yi} sind die Elemente des Operatorpolynoms $V_Y(B)$.

wobei

$$c_{YX}(z) = \sum_{k=-\infty}^{\infty} c_{YX}(k) z^k$$

Erzeugungsfunktion der
Kreuzkovarianzen $c_{YX}(k)$;

$$c_{XX}(z) = \sum_{k=-\infty}^{\infty} c_{XX}(k) z^k$$

Erzeugungsfunktion der
Autokovarianzen $c_{XX}(k)$;

$$V_Y(z) = \sum_{k=0}^{\infty} v_{Yk} z^k$$

Erzeugungsfunktion der
Elemente des Operatorpo-
lynoms $V_Y(B)$.

Aus Gleichung (5.19) ist ersichtlich, warum die Kreuzkovarianzen (und damit die Kreuzkorrelationen) nur unzureichende Informationen über die Art des zwischen Y_t und X_t bestehenden Kausalzusammenhangs vermitteln: $c_{XX}(z)$ weist sowohl positive wie negative Exponenten von z auf, und da $V_Y(z)$ keine negativen Exponenten von z besitzt, können in $c_{YX}(z)$ positive und negative Exponenten von z auftreten. Die $c_{YX}(k)$ werden also im allgemeinen Werte ungleich null für positive und negative k annehmen, und es ist aus ihnen dann nicht zu entnehmen, wie die Richtung der Kausalität zwischen Y_t und X_t ist.¹⁾

Gleichung (5.19) vereinfacht sich jedoch erheblich, wenn X_t weißes Rauschen ist.²⁾ In diesem Fall sind die Autokovarianzen von X_t null für $k \neq 0$, und es folgt:

$$(5.20) \quad c_{YX}(k) = v_{Yk} c_{XX}(0) \quad k \geq 0$$

Die $c_{YX}(k)$ sind nun null für $k < 0$, und die Gefahr einer Fehlinterpretation der Kreuzkovarianzen ist ausgeräumt.

1) "If one looked at $r_{xy}(\cdot)$ in an attempt to check feedback, one would easily be misled, since $\rho_{xy}(\cdot)$ can have nonzero values at negative lags even when there is no feedback present". Haugh/Box (1977), S. 125. Zur Terminologie: $\rho_{xy}(\cdot) = r_{XY}(k)$, $r_{xy}(\cdot) = r_{xy}(k)$.

2) Es gilt also in (5.10): $G_X(B) = 1$ bzw. $X_t = E_{Xt}$.

Falls zwischen Y_t und X_t eine Feedback-Beziehung besteht - Y_t beeinflußt X_t und X_t beeinflußt Y_t -, ist die Erzeugungskfunktion der Kreuzkovarianzen $c_{YX}(k)$ noch wesentlich komplizierter als die in (5.19). Auch in diesem Fall ergeben sich nur dann relativ einfach zu interpretierende Kreuzkovarianzen, wenn Y_t und X_t weißes Rauschen sind.¹⁾

2. Die Varianzen und Kovarianzen der $r_{yx}(k)$ sind nach Maßgabe von Bartletts Formel abhängig von den (theoretischen Autokorrelationen) $r_{YY}(k)$ und $r_{XX}(k)$ sowie den (theoretischen Kreuzkorrelationen) $r_{YX}(k)$.²⁾ Tabelle 26 listet die Formeln für $\text{var}(r_{yx}(k))$ und $\text{cov}(r_{yx}(k)r_{yx}(k+1))$ für Kombinationen von jeweils dichotomisierten Ausprägungen von Autokorrelation und Abhängigkeit der Prozesse Y_t und X_t auf. In Ergänzung zu Tabelle 26 sollen noch die Varianzen und Kovarianzen der $r_{yx}(k)$ für einen Spezialfall genannt werden. Falls Y_t und X_t jeweils weißes Rauschen sind und die $r_{YX}(k)$ ungleich null nur innerhalb eines bestimmten Lag-Bereichs, zu dem weder k noch $(k + 1)$ zählen, gilt:

$$(5.21) \quad \text{var}(r_{yx}(k)) \approx T^{-1}$$

$$(5.22) \quad \text{cov}(r_{yx}(k)r_{yx}(k+1)) \approx 0$$

Wie die in Tabelle 26 ausgewiesenen Werte zeigen, machen die hohen Varianzen und Kovarianzen der $r_{yx}(k)$ die Identifikation des zugrundeliegenden Kausalzusammenhangs zu einer kaum lösbaren Aufgabe, wenn Y_t und X_t autokorreliert sind. Es können dann Sequenzen von $r_{yx}(k)$ auftreten, die den Eindruck einer Beziehung erwecken, auch wenn die Prozesse Y_t

1) Vgl. Granger/Newbold (1977), S. 231.

2) Vgl. Bartlett (1962), S. 289, Box/Jenkins (1976), S. 376 f. In Tabelle 26 wie auch in den Gleichungen (5.21) und (5.22) ist jeweils angenommen, T (die Zahl der Beobachtungen) sei groß gegenüber k .

Tabelle 26

Varianzen und Kovarianzen der Schätzungen der Kreuzkorrelationen

1. Y_t, X_t autokorreliert/abhängig

$$\text{var}(r_{yx}(k)) \approx T^{-1} \sum_{v=-\infty}^{\infty} (r_{YY}(v)r_{XX}(v) + r_{YX}(k+v)r_{YX}(k-v) + r_{YX}^2(k)(r_{YX}^2(v) + 2^{-1}r_{YY}^2(v) +$$

$$2^{-1}r_{XX}^2(v)) - 2r_{YX}(k)(r_{YY}(v)r_{YX}(v+k) + r_{YX}^2(v)r_{XX}(v+k)))$$

$$\text{cov}(r_{yx}(k)r_{yx}(k+1)) \approx T^{-1} \sum_{v=-\infty}^{\infty} (r_{YY}(v)r_{XX}(v+1) + r_{YX}^2(-v)r_{YX}(v+2k+1) + r_{YX}(k)r_{YX}(k+1)(r_{YX}^2(v) + 2^{-1}r_{YY}^2(v) + 2^{-1}r_{XX}^2(v)) - r_{YX}(k)(r_{YY}(v)r_{YX}(v+k+1) +$$

$$r_{YX}^2(-v)r_{XX}(v+k+1)) - r_{YX}(k+1)(r_{YY}(v)r_{YX}(v+k) + r_{YX}^2(-v)r_{XX}(v+k)))$$

2. Y_t, X_t autokorreliert/unabhängig

$$\text{var}(r_{yx}(k)) \approx T^{-1} \sum_{v=-\infty}^{\infty} (r_{YY}(v)r_{XX}(v))$$

$$\text{cov}(r_{yx}(k)r_{yx}(k+1)) \approx T^{-1} \sum_{v=-\infty}^{\infty} (r_{YY}(v)r_{XX}(v+1))$$

3. Y_t, X_t weißes Rauschen/abhängig

$$\text{var}(r_{yx}(k)) \approx T^{-1} \sum_{v=-\infty}^{\infty} (r_{YX}(k+v)r_{YX}(k-v) + r_{YX}^2(k)r_{YX}(v))$$

$$\text{cov}(r_{yx}(k)r_{yx}(k+1)) \approx T^{-1} \sum_{v=-\infty}^{\infty} (r_{YX}^2(-v)r_{YX}(v+2k+1) + r_{YX}(k)r_{YX}(k+1)r_{YX}^2(v))$$

4. Y_t, X_t weißes Rauschen/unabhängig

$$\text{var}(r_{yx}(k)) \approx T^{-1}$$

$$\text{cov}(r_{yx}(k)r_{yx}(k+1)) \approx 0$$

und X_t tatsächlich unabhängig sind.¹⁾

Sind Y_t und X_t jeweils weißes Rauschen, wird das geschätzte Kreuzkorrelogramm zumindestens in jenen Lag-Bereichen einfacher interpretierbar, in denen die $r_{YX}(k)$ null sind.

3. Die hier durchgeführte Kausalitätsanalyse bedient sich aus den genannten Gründen der Transformation zu weißem Rauschen vor der Berechnung des Kreuzkorrelogramms. Zur Transformation sind univariate ARIMA-Modelle verwendet, die mithilfe der von Box/Jenkins empfohlenen iterativen Strategie identifiziert und geschätzt sind.

4. Im Interesse einer anschaulicheren Darstellung sind in Tabelle 27 die zwischen zwei Prozessen X_t und Y_t möglichen Kausalmuster gekennzeichnet. Die Kreuzkorrelationen $r_{UV}(k)$ beziehen sich auf weißes Rauschen U_t und V_t , wobei

$$(5.23) \quad \begin{aligned} a_Y(B)Y_t &= b_Y(B)U_t \\ a_X(B)X_t &= b_X(B)V_t \end{aligned}$$

U_t (V_t) sind also mit Y_t (X_t) durch univariate ARMA-Modelle (bzw. ARIMA-Modelle, wenn Y_t (X_t) homogen nichtstationär sind) verbunden.

Einzelne Pfeile, die in eine Richtung zeigen, bedeuten einfache Granger-Kausalität, Pfeile, die in beide Richtungen zeigen, Granger-Feedback und parallele Linien gleichzeitige Granger-Kausalität. Die einzelne senkrechte Linie steht für die Nichtexistenz von Granger-Kausalität.

1) "One may be misled in such situations by attributing some significance to apparent patterns in the cross-correlation function, which in fact are a result of the sampling properties of the estimates used ... This can happen even if the two series are in fact independent ...". Haugh/Box (1977), S. 122. S. auch Pierce (1977): "The distribution of the sample cross-correlation ... , even under a null hypothesis of no causality, is more complicated in the presence of autocorrelation, and the type of autocorrelation often found is such that ignoring these complications results in grossly overestimating relationships that don't exist".

Tabelle 27

Beschreibung der zwischen den stochastischen Prozessen Y_t und X_t möglichen Kausalmuster

$Y \longrightarrow X$	$r_{UV}(k) \neq 0$	für mindestens ein $k < 0$
	$r_{UV}(k) = 0$	für $k \geq 0$
$Y \Longrightarrow X$	$r_{UV}(k) \neq 0$	für mindestens ein $k < 0$
	$r_{UV}(k) \neq 0$	für $k = 0$
	$r_{UV}(k) = 0$	für $k > 0$
$X \longrightarrow Y$	$r_{UV}(k) \neq 0$	für mindestens ein $k > 0$
	$r_{UV}(k) = 0$	für $k \leq 0$
$X \Longrightarrow Y$	$r_{UV}(k) \neq 0$	für mindestens ein $k > 0$
	$r_{UV}(k) \neq 0$	für $k = 0$
	$r_{UV}(k) = 0$	für $k < 0$
$Y \dashrightarrow X$	$r_{UV}(k) \neq 0$	für mindestens ein $k < 0$
	$r_{UV}(k) = 0$	für $k = 0$
	$r_{UV}(k) \neq 0$	für mindestens ein $k > 0$
$Y \dashleftarrow X$	$r_{UV}(k) \neq 0$	für mindestens ein $k < 0$
	$r_{UV}(k) \neq 0$	für $k = 0$
	$r_{UV}(k) \neq 0$	für mindestens ein $k > 0$
$Y \Longleftarrow X$	$r_{UV}(k) = 0$	für $k \neq 0$
	$r_{UV}(k) \neq 0$	für $k = 0$
$Y \mid X$	$r_{UV}(k) = 0$	für alle k

5. Regelmäßig sind nur die Schätzungen $\hat{u}_t$ und $\hat{v}_t$ von U_t und V_t bekannt. $\hat{u}_t$ und $\hat{v}_t$ sind in der in Abschnitt 423⁴ vorgestellten Form definiert, d.h. als Residuen der Transformation der Originalserien, wobei anstelle der Parameter in (5.23) die Schätzungen $\hat{a}_Y(B)$, $\hat{b}_Y(B)$, $\hat{a}_X(B)$ und $\hat{b}_X(B)$ verwendet sind.

Im Falle der Unabhängigkeit von X und Y sind die Kreuzkorrelationen $r_{\hat{u}\hat{v}}(k)$ asymptotisch unkorreliert und normal verteilt mit Mittelwert null und Varianz f^{-1} , wobei f die Zahl der zur Berechnung der $r_{\hat{u}\hat{v}}(k)$ zur Verfügung stehenden Beobachtungen ist.¹⁾ In den unten ausgewiesenen Kreuzkorrelogrammen ist daher $f^{-1/2}$ als Standardfehler der $r_{\hat{u}\hat{v}}(k)$ aufgeführt.

Tests der Signifikanz einer Gruppe von $r_{\hat{u}\hat{v}}(k)$ sind mithilfe der von Haugh entwickelten Statistik S_K möglich, wobei²⁾

$$(5.24) \quad S_K = f \sum_{k=-K}^K r_{\hat{u}\hat{v}}^2(k)$$

Unter der Nullhypothese der Unabhängigkeit von Y und X ist S_K Chi-Quadrat verteilt mit $(2K + 1)$ Freiheitsgraden. Falls S_K den kritischen Wert der Chi-Quadrat-Verteilung für die gewählte Irrtumswahrscheinlichkeit übersteigt, ist die Nullhypothese abzulehnen.

Die S_K -Statistik ist unten für die Lag-Bereiche $1 \leq k \leq 24$, $-1 \geq k \geq -24$ und $-24 \leq k \leq 24$ berechnet. Die Verwendung der S_K -Statistik für einen begrenzten Lag-Bereich setzt voraus, daß außerhalb dieses Bereichs keine signifikant von null verschiedenen Koeffizienten auftreten. Für den Lag-Bereich $-24 \leq k \leq 24$ wird diese Annahme im allgemeinen gerechtfertigt sein, da Beziehungen mit einer zeitlichen Verzögerung von sechs Jahren selten sein dürften. Für die beiden anderen Lag-Bereiche ist jedoch mit signifikanten Koeffizienten auch außerhalb der Grenzen des Bereichs zu rechnen. Der S_K -Test ist hier mit einem gewissen Vorbehalt zu interpretieren, der sich aus der Möglichkeit der Kovarianz der im berücksichtigten Lag-Bereich befindlichen Koeffizienten mit den außerhalb dieses Lag-Bereichs liegenden Koeffizienten herleitet.

1) Vgl. Haugh (1976), S. 379 f., Haugh/Box (1977), S. 123.

2) Vgl. Haugh (1976), S. 382.

533 Die Identifikation der Transferfunktion-Form

1. Es sei die Transferfunktion-Form (vgl. Gleichung (5.10)) zu identifizieren, wobei das Interesse sich auf den ersten Teil von Gleichung (5.10) richtet; der zweite Teil, der den Erzeugungsmechanismus von X_t beschreibt, ist ein univariates ARMA-Modell, das mithilfe der in Abschnitt 423 vorgestellten Strategie identifiziert werden kann.

Die iterative Strategie von Box/Jenkins und Granger/Newbold verwendet zur Identifikation der Transferfunktion-Form die in Tabelle 28 ausgewiesenen Phasen.¹⁾ Die Phasen 2 und 3 sind im folgenden erläutert.

2. Analog zum ersten Teil von Gleichung (5.10) lässt sich die Transferfunktion-Form der Prozesse U_t und V_t - die mit Y_t und X_t gemäß Gleichung (5.23) verbunden seien - darstellen als:

$$(5.25) \quad U_t = A_U(B)B^{b_U-1}(B)V_t + C_U(B)D_U^{-1}(B)E_{Ut} \\ = V_U(B)V_t + G_U(B)E_{Ut}$$

wobei

$$A_U(B) = (a_{U0} - a_{U1}B - \dots - a_{Us}B^s)$$

$$B_U(B) = (1 - b_{U1}B - \dots - b_{Ur}B^r)$$

$$C_U(B) = (1 - c_{U1}B - \dots - c_{Um}B^m)$$

1) Box/Jenkins fordern keine Transformation zu weißem Rauschen für beide Reihen vor Berechnung des Kreuzkorrelogramms. Sie empfehlen die Transformation zu weißem Rauschen nur für die "Input"-Variable X_t ; die "Output"-Variable wird mithilfe der für die "Input"-Variable identifizierten Operatorpolynomen transformiert (vgl. Box/Jenkins (1976), S. 379 f.). Da für die hier analysierten Beziehungen nicht a priori bekannt ist, welches die "Input"-Variable ist, wird der Vorschlag von Box/Jenkins nicht übernommen. Stattdessen sind jeweils beide Reihen - Granger/Newbold folgend - zu weißem Rauschen transformiert.

Tabelle 28

Die Phasen der iterativen Strategie von Box/Jenkins und Granger/Newbold zur Identifikation der Transferfunktion-Form

- Phase 1: Identifikation und Schätzung der zur Transformation der autokorrelierten Prozesse Y_t und X_t zu weißem Rauschen U_t und V_t verwendeten univariaten ARIMA- bzw. ARMA-Modelle.
- Phase 2: Identifikation der Transferfunktion-Form der Prozesse U_t und V_t und Erstellung grober Schätzungen der Parameter.
- Phase 3: Identifikation der Operatorpolynome der Transferfunktion-Form der Prozesse Y_t und X_t aus den Operatorpolynomen der Transferfunktion-Form der Prozesse U_t und V_t unter Heranziehung der Operatorpolynome der zur Transformation verwendeten univariaten ARIMA- bzw. ARMA-Modelle.

$$D_U(B) = (1 - d_{U1}B - \dots - d_{Un}B^n)$$

$$V_U(B) = (v_{U0} + v_{U1}B + \dots)$$

$$G_U(B) = (1 + g_{U1}B + \dots)$$

$$E(U_t U_{t'}) = E(V_t V_{t'}) = E(E_{Ut} E_{Ut'}) = 0 \quad t \neq t'$$

$$E(V_t E_{Ut'}) = 0 \quad \text{alle } t \text{ und } t'$$

$$E(U_t) = E(V_t) = E(E_{Ut}) = 0$$

Es ist unterstellt, daß alle Wurzeln der Gleichungen

$$A_U(B)B^b = 0$$

$$B_U(B) = 0$$

$$C_U(B) = 0$$

$$D_U(B) = 0$$

außerhalb des Einheitskreises liegen.

Im Unterschied zu Gleichung (5.10) ist in Anlehnung an Box/Jenkins in Gleichung (5.24) der Parameter b eingeführt, der den Verzug der Reaktion von U_t auf V_t mißt.¹⁾ Die Größen (r, s, b) werden im weiteren als Ordnung der Transferfunktion $A_U(B)B^bB^{-1}(B)$ bezeichnet. Dabei ist $r(s)$ der größte in $B_U(B)$ ($A_U(B)$) auftretende Lag (vgl. Gleichung (5.25)). Die Parameter v_{UK} des Operatorpolynoms $V_U(B)$ sind den Kreuzkorrelationen $r_{UV}^{(k)}$ direkt proportional, wie sich leicht nachweisen läßt.²⁾ Wegen der Unabhängigkeit von V_t und E_{Ut} für alle t und t' gilt nämlich:

$$(5.26) \quad E(U_t V_{t-k}) = E(v_{UK} V_{t-k}^2)$$

oder:

$$v_{UK} = r_{UV}^{(k)} \sigma_U \sigma_V^{-1}$$

wobei

$$\sigma_U^2 = E(U_t^2)$$

$$\sigma_V^2 = E(V_t^2)$$

Da die v_{UK} -Gewichte somit den Kreuzkorrelationen $r_{UV}^{(k)}$ nach Maßgabe des Faktors $\sigma_U \sigma_V^{-1}$ direkt proportional sind, können sie direkt aus dem Kreuzkorrelogramm von U_t und V_t hergeleitet werden.

Zwischen den v_{UK} und den a_{UK} bzw. b_{UK} bestehen wegen Gleichung (5.25) die folgenden Beziehungen:

1) Vgl. Box/Jenkins (1976), S. 338.

2) Vgl. ibid., S. 380, Granger/Newbold (1977), S. 238 f.

$$(5.27) \quad (1 - b_{U1}B - \dots - b_{Ur}B^r)(v_{U0} + v_{U1}B + \dots) = (a_{U0} - a_{U1}B - \dots - a_{Us}B^s)B^b$$

Nach Gleichsetzung der Koeffizienten von B ergibt sich das folgende System von Differenzen-Gleichungen:¹⁾

$$(5.28) \quad \begin{aligned} v_{Uk} &= 0 \quad k < b \\ v_{Uk} &= b_{U1}v_{U,k-1} + b_{U2}v_{U,k-2} + \dots + b_{Ur}v_{U,k-r} \\ &\quad + a_{U0} \quad k = b \\ v_{Uk} &= b_{U1}v_{U,k-1} + \dots + b_{Ur}v_{U,k-r} - a_{U,k-b} \\ &\quad k = (b+1), (b+2), \dots, (b+s) \\ v_{Uk} &= b_{U1}v_{U,k-1} + \dots + b_{Ur}v_{U,k-r} \quad k > (b+s) \end{aligned}$$

Die Ordnung (r,s,b) der Transferfunktion $A_U(B)B^bB^{-1}(B)$ spiegelt sich demnach in den v_{Uk} bzw. den $r_{UV}(k)$ in folgender Weise wider:²⁾

- die ersten b Koeffizienten v_{Uk} ($k = 0, 1, \dots, (b-1)$) sind null;
- weitere $(s - r + 1)$ Koeffizienten v_{Uk} ($k = b, (b+1), \dots, (b+s-r)$) folgen keinem bestimmten Muster;
- die Koeffizienten v_{Uk} ($k = (b+s-r+1), (b+s-r+2), \dots$) folgen einer Differenzengleichung r -ter Ordnung.

Die Ordnung m von $C_U(B)$ ist nach Granger/Newbold gleich der

1) Vgl. Box/Jenkins (1976), S. 347.

2) Vgl. *ibid.*

größeren von $B_U(B)$ und $A_U(B)B^b$, falls diese unterschiedlich sind, und geringer oder gleich der gemeinsamen Ordnung von $B_U(B)$ und $A_U(B)B^b$, falls diese gleich sind.¹⁾

Wenn also

$$r \neq (s + b)$$

ist

$$m = \max_{r, (s+b)}$$

Wenn

$$r = (s + b)$$

ist

$$m \leq r$$

Box/Jenkins²⁾ schlagen eine direkte Identifikation von $C_U(B)$ aus dem Autokorrelogramm von L_t vor, wobei

$$(5.29) \quad L_t = U_t - A_U(B)B^b B_U^{-1}(B)V_t$$

Die Ordnung von $D_U(B)$ - die bei der in den Gleichungen (5.10) und (5.24) angenommenen Form der Beziehungen theoretisch gleich der von $B_U(B)$ sein müßte - läßt sich ebenfalls mithilfe des Autokorrelogramms von L_t ermitteln.

Bei Vorliegen einer Realisation $\hat{u}_t$ und $\hat{v}_t$ lassen sich grobe

1) Vgl. Granger/Newbold (1977), S. 235. Die exakte Bestimmung von m für $r = (s + b)$ ist bei Granger/Newbold (1977) S. 77, beschrieben.

2) Vgl. Box/Jenkins (1976), S. 384.

Schätzungen der Parameter a_{Uk} und b_{Uk} aus dem System von Gleichungen (5.28) gewinnen.¹⁾ Für die Parameter c_{Uk} und d_{Uk} ergeben sich grobe Schätzungen mithilfe der bei univariaten ARIMA- bzw. ARMA-Modellen verwendeten Technik.

3. Aus den Operatorpolynomen der Transferfunktion-Form der Prozesse U_t und V_t sowie aus den zur Transformation verwendeten univariaten ARIMA- bzw. ARMA-Modellen lassen sich die Operatorpolynome der Transferfunktion-Form von Y_t und X_t wie folgt herleiten:

$$(5.30) \quad A_Y(B) = A_U(B)B^b b_Y(B) a_X(B)$$

$$(5.31) \quad B_Y(B) = B_U(B) b_X(B) a_Y(B)$$

$$(5.32) \quad C_Y(B) = C_U(B) b_Y(B)$$

$$(5.33) \quad D_Y(B) = D_U(B) a_Y(B)$$

534 Schätzung der Transferfunktion-Form

Die im zweiten Teil der empirischen Analyse identifizierten Transferfunktion-Formen (vgl. Gleichung (5.10)) sind mithilfe eines nichtlinearen Verfahrens - dem von Newton-Raphson - geschätzt.²⁾ Formal gesehen entspricht das Vorgehen dem bei der Schätzung univariater ARMA-Modelle, d.h. ausgehend von dem Gleichungstypus (4.49) wird iterativ derjenige Parameter-Vektor bestimmt, für den die Summe der quadrierten Residuen ein Minimum wird. In Ergänzung zu Gleichung (4.49) sind hier noch die Lags der unabhängigen Variablen zu berücksichtigen.

Wie in Abschnitt 4233 ausgeführt, sind die üblichen Signifikanz-Tests auf die Ergebnisse nichtlinearer Schätzungen nicht ohne weiteres anwendbar. Die genannten Test-Ergebnisse sollten daher nur im Sinne ungefährender Vergleichsmaße interpretiert werden.

1) Der Unterschied zwischen u_t und $\hat{u}_t$ und analog zwischen v_t und $\hat{v}_t$ ist in Abschnitt 4234 erklärt.

2) Vgl. Draper/Smith (1966), S. 277. Das für die Schätzung univariater ARIMA- bzw. ARMA-Modelle verwendete Programm ESTMAT ist nicht zur Schätzung bivariater Modelle geeignet. Das hier benutzte Programm wurde unter der Aufsicht von Prof. Newbold von Dr. Chenen, University of California, San Diego, entwickelt.

tiert werden.

535 Diagnostic Checks

1. Für die Diagnostic Checks¹⁾ der Adäquanz der identifizierten und geschätzten Transferfunktion-Form empfiehlt sich die Inspektion der Autokorrelationen $r_{\hat{e}_Y \hat{e}_Y}(k)$ und der Kreuzkorrelationen $r_{\hat{e}_Y \hat{e}_X}(k)$.

Die $\hat{e}_{Yt}$ und $\hat{e}_{Xt}$ sind die Schätzungen der E_{Xt} und E_{Yt} in Gleichung (5.10).²⁾

Wegen der den Gleichungen (5.1) und (5.3) zugrundegelegten Annahmen gilt:

$$(5.34) \quad E(E_{Yt} E_{Yt'}) = d_{tt'} \sigma_Y^2$$

Die $r_{\hat{e}_Y \hat{e}_Y}(k)$ sollten somit den Autokorrelationen einer Realisation von weißem Rauschen entsprechen. Da ferner die Transferfunktion-Form (5.10) einen kausalen Zusammenhang unterstellt, bei dem X Einfluß auf Y, aber Y keinen Einfluß auf X ausübt, folgt:

$$(5.35) \quad E(E_{Yt} E_{Xt'}) = 0 \quad \text{alle } t \text{ und } t'$$

In den Kreuzkorrelationen $r_{\hat{e}_Y \hat{e}_X}(k)$ sollte sich die Unabhängigkeit der E_{Yt} und E_{Xt} widerspiegeln.

2. Tests der $r_{\hat{e}_Y \hat{e}_Y}(k)$ und $r_{\hat{e}_Y \hat{e}_X}(k)$ sind mithilfe der Statistiken Q' , S' und S'' möglich.³⁾

1) Vgl. Box/Jenkins (1976), S. 392 f., Granger/Newbold (1977), S. 241 f.

2) Bezüglich des Unterschiedes zwischen e_{Yt} und $\hat{e}_{Yt}$ bzw. e_{Xt} und $\hat{e}_{Xt}$ wird auf die Ausführungen in Abschnitt 4234 verwiesen.

3) Vgl. Pierce (1972).

Unter der Hypothese $r_{E_Y E_Y}(k) = 0$, $k > 0$, folgt Q' approximiert einer Chi-Quadrat-Verteilung mit $(K - m' - n')$ Freiheitsgraden, wobei

$$(5.36) \quad Q' = f \sum_{k=1}^K r_{\hat{e}_Y \hat{e}_Y}^2(k)$$

m' Ordnung von $C_Y(B)$;

n' Ordnung von $D_Y(B)$;

f Zahl der Residuen.

Die Statistik S' ist unter der Hypothese $r_{E_Y E_X}(k) = 0$, alle k , approximiert Chi-Quadrat verteilt mit $(K + 1 - (r' + s' + 1))$ Freiheitsgraden, wobei

$$(5.37) \quad S' = f \sum_{k=1}^K r_{\hat{e}_Y \hat{e}_X}^2(k)$$

s' Ordnung von $A_X(B)$;

r' Ordnung von $B_X(B)$.

S'' folgt unter der Hypothese $r_{E_Y E_X}(k) = 0$, alle k , approximiert einer Chi-Quadrat-Verteilung mit K Freiheitsgraden, wobei

$$(5.38) \quad S'' = f \sum_{k=-1}^{-K} r_{\hat{e}_Y \hat{e}_X}^2(k)$$

K sollte jeweils groß genug gewählt werden, um mögliche signifikant von null abweichende Koeffizienten einzuschließen.

Modell-Inadäquanz wird angezeigt, wenn Q' bzw. S' bzw. S'' für die gewählte Irrtumswahrscheinlichkeit und die jeweilige Zahl der Freiheitsgrade den kritischen Wert der Chi-Quadrat-Verteilung übersteigt.

3. Die Ursachen der Modell-Inadäquanz lassen sich aufgrund der folgenden Überlegungen lokalisieren.¹⁾ Falls anstelle des richtigen Modells (vgl. Gleichung (5.10))

$$Y_t = V_Y(B)X_t + G_Y(B)E_{Yt}$$

ein falsches Modell der Form

$$(5.39) \quad Y_t = V_Y^0(B)X_t + G_Y^0(B)E_{Yt}$$

identifiziert und geschätzt ist, folgt:

$$(5.40) \quad E_{Yt}^0 = G_Y^{0^{-1}}(B)(V_Y(B) - V_Y^0(B))X_t + G_Y^{0^{-1}}(B)G_Y(B)E_{Yt}$$

Aus (5.40) ist zu entnehmen, daß bei einer Misspezifikation in der Form (5.39) die E_{Yt}^0 autokorreliert und die Kreuzkorrelationen $r_{E_Y^0 E_X}(k)$ nicht alle null sein werden.²⁾

Zwei Sonderfälle von (5.39) verdienen besondere Erwähnung:³⁾

- $V_Y(B)$ ist korrekt spezifiziert ($V_Y(B) = V_Y^0(B)$), jedoch $G_Y(B) \neq G_Y^0(B)$. Dann ist

$$(5.41) \quad E_{Yt}^0 = G_Y^{0^{-1}}(B)G_Y(B)E_{Yt}$$

E_{Yt}^0 ist also wiederum nicht weißes Rauschen, aber die $r_{E_Y^0 E_X}(k)$ sind null für alle k .

- $G_Y(B)$ ist korrekt spezifiziert ($G_Y(B) = G_Y^0(B)$), jedoch $V_Y(B) \neq V_Y^0(B)$. Dann ist

1) Vgl. Box/Jenkins (1976), S. 392 f.

2) Da $E(E_{Y,t}^0 E_{X,t-k}) \neq 0$ für mindestens ein k .

3) Vgl. Box/Jenkins (1976), S. 392.

$$(5.42) \quad E_{Yt}^0 = G_Y^{-1}(B)(V_Y(B) - V_Y^0(B))X_t + E_{Yt}$$

Wiederum ist E_{Yt}^0 nicht weißes Rauschen; hier gilt jedoch zusätzlich $r_{E_Y E_X}^0(k) \neq 0$ für mindestens ein k .

Hinweise auf die Neuspezifikation der Transferfunktion und des Noise-Modells aufgrund des Erscheinungsbildes der $r_{\hat{e}_Y \hat{e}_Y}(k)$ und $r_{\hat{e}_Y \hat{e}_X}(k)$ sind bei Box/Jenkins (1976) gegeben.¹⁾

536 Zur Anwendung der iterativen Strategie von Box/Jenkins und Granger/Newbold

1. Wie im Falle univariater ARIMA- bzw. ARMA-Modelle muß auf die Grenzen der Anwendbarkeit der iterativen Strategie von Box/Jenkins und Granger/Newbold hingewiesen werden. Auch ein mehrmaliges Durchlaufen der verschiedenen Phasen der Strategie - Kausalitätsanalyse, Identifikation und Schätzung der Transferfunktion-Form, Diagnostic Checks - garantiert nicht die Wahl des "richtigen" Modells. Da die Verbindung der Ansätze von Box/Jenkins und Granger/Newbold zur Identifikation überparametrisierter Modelle führen kann,²⁾ die im Interesse stabiler Parameter-Schätzungen in Richtung auf sparsamere Parametrisierung verändert werden müssen, fließt ein zusätzliches subjektives Element in die Modellierungsstrategie ein.

2. Die Autokorrelationen und Kreuzkorrelationen sowie die (bei der Transformation zu weißem Rauschen notwendigen) partiellen Autokorrelationen sind jeweils für die in Abschnitt 4235 genannten Lag-Bereiche ausgewiesen. Die verwendeten

1) Vgl. Box/Jenkins (1976), S. 393 f.

2) Vgl. Granger/Newbold (1977), S. 240.

Symbole und die Formeln der Standardfehler entsprechen im Interesse der Kontinuität der Darstellung den im ersten Teil der empirischen Analyse (vgl. Abschnitt 4235) vorgestellten.

Es sei noch einmal ausdrücklich darauf verwiesen, daß die Standardfehler der geschätzten Auto- und Kreuzkorrelationen für kleine Lags die jeweilige Standardabweichung überschätzen können.¹⁾

54 Die gewählte Untersuchungsperiode

Wegen der Begrenztheit der Zahl der zur Verfügung stehenden Beobachtungen sowie der starken Beanspruchung der Daten durch die verwendete iterative Strategie ist auf eine Post-Sample-Bewertung verzichtet. Für diesen zweiten Teil der empirischen Analyse wird also die Gesamtheit der Beobachtungen (91 Quartalswerte von 1954.1 - 1976.3) verwendet.

55 Vorstellung der einbezogenen Variablen

Die Theorie der "Psychological Economics" definiert keinen umfassenden Katalog ökonomischer Variablen für die Analyse des Beziehungsmusters, in das der ICS eingebettet ist. Zwar wird die Bedeutung des ICS für die Prognose von Gebrauchsgüter- und Autoausgaben betont; welche weiteren ökonomischen Variablen eine nennenswerte Beziehung zum ICS aufweisen könnten, wird jedoch nicht eindeutig festgelegt.²⁾

Um eine Ausuferung der Analyse zu vermeiden, sind im folgenden neben dem ICS nur solche ökonomischen Variablen berücks-

1) Vgl. die Diskussion in Abschnitt 4234.

2) Dies erklärt auch die Vielzahl von Variablen, die in den in Abschnitt 2 vorgestellten Untersuchungen neben dem ICS aufgeführt werden.

sichtigt, die in den bisherigen Untersuchungen verwendet wurden. Dieses Verfahren besitzt den Vorteil, eine Vergleichbarkeit der Ergebnisse zu ermöglichen.

Die neben dem ICS berücksichtigten ökonomischen Variablen sind mit ihren Abkürzungen sowie ihren Quellen in Tabelle 29 ausgewiesen. Ebenfalls genannt sind die Untersuchungen, in denen die Variablen verwendet wurden. Die Aufführung von Untersuchungen, die die Beziehung des ICS zu Gebrauchs- und Autoausgaben betreffen, erübrigt sich, da praktisch jede der in Abschnitt 2 vorgestellten Arbeiten diesen Komplex berührt.

Es ist möglich, daß die Quellen der hier verwendeten Variablen nicht immer mit denen in den genannten Untersuchungen übereinstimmen, da dort im allgemeinen die Quellen der Daten nicht explizit gemacht sind.

56 Die Ergebnisse des zweiten Teils der empirischen Analyse

561 Identifikation und Schätzung der zur Transformation zu weißem Rauschen verwendeten Modelle

Im folgenden sind die Ergebnisse der Transformation des ICS und der in Tabelle 29 ausgewiesenen Variablen zu Realisationen von weißem Rauschen berichtet. Besondere Aufmerksamkeit ist dabei der Transformation des ICS sowie der Gebrauchsgüter- und Autoausgabenserien gewidmet.

5611 Identifikation

Im Interesse der Übersichtlichkeit ist die Identifikation der Zahl der zur Beseitigung von Nichtstationarität notwen-

Tabelle 29

Liste der in den zweiten Teil der empirischen Analyse
einbezogenen ökonomischen Variablen

Name und Abkürzung	Quelle	Verwendung in der Unter- suchung von
CD _t = Consumer durable goods expenditures	Datenbänder des Survey Research Center	(vgl. Ab- schnitt 22)
CA _t = Consumer expenditures on motor ve- hicles and parts	Datenbänder des Survey Research Center	(vgl. Ab- schnitt 22)
YDQU _t = Dis- posable perso- nal income	Datenbänder des Survey Research Center	Mueller (1963) Adams/Green (1965) Suits/Sparks (1965) Shapiro (1972)
UNRA _t = Un- employment rate	1954.1 - 1975.4: HCI, S. 89 1976.1 - 1976.3: BCD, 4/77, S. 61	Mueller (1963) Adams/Klein (1965) Adams/Green (1965) Shapiro (1972)
WOWE _t = Length of average work week in manufacturing industry	1954.1 - 1975.4: HCI, S. 78 1976.1 - 1976.3: BCD, 4/77, S. 60	Adams/Green (1965)
HOUSE _t = Index of new private housing units	1954.1 - 1975.4: HCI, S. 85 1976.1 - 1976.3: BCD, 4/77, S. 66	Adams/Green (1965)
IMPR _t = Impli- cit price de- flator for personal con- sumption ex- penditures	1954.1 - 1974.1: NIP, S. 264 1974.2 - 1976.3: SCB, 4/77, S. 2	Adams/Klein (1972) Shapiro (1972)

(Fortsetzung der Tabelle auf der nächsten Seite)

(noch: Tabelle 29)

SPI _t =	1954.1 - 1975.4: HCI, S. 83	Shapiro (1972)
Standard and	1976.1 - 1976.3: BCD, 4/77,	
Poors index of	S. 68	
500 industrial		
common stocks		
CAPA _t = Index	1954.1 - 1975.4: HCI, S. 148	Adams/Green
of capital	1976.1 - 1976.3: BCD, 4/77,	(1965)
utilization	S. 63	
ACLA _t =	1954.1 - 1975.4: HCI, S. 78	Adams/Green
Difference	1976.1 - 1976.3: BCD, 4/77,	(1965)
between acces-	S. 60	
sion and		
layoff rate in		
manufacturing		
industry		

Legende:

HCI	Handbook of Cyclical Indicators;
BCD	Business Conditions Digest;
SCB	Survey of Current Business;
NIP	The National Income and Product Accounts of the United States, 1929 - 1974.


CD_t, CA_t und YDQU_t sind für Preisveränderungen, die Zahl der der Familien sowie saisonal adjustiert; UNRA_t, WOVE_t, HOUSE_t, IMPR_t, CAPA_t und ACLA_t sind saisonal adjustiert. Der Zeit-Index bezieht sich auf Quartalswerte.

digen Differenzen d für alle Serien der Identifikation der Ordnung (p,q) vorangestellt.

56111 Identifikation der Ordnung d1. ICS_t

Eine erste Information über die Zeitreihennatur des ICS ergibt sich aus der Betrachtung des Erscheinungsbildes der Originalwerte (vgl. Zeichnung 24). Der optische Eindruck

Zeichnung 24
INDEX OF CONSUMER SENTIMENT, 1954.1. - 1976.3.



weist zwar nicht deutlich auf Nichtstationarität, wohl aber auf die Existenz von Autokorrelation in der ICS-Serie hin. Keineswegs läßt sich aufgrund von Zeichnung 24 die Annahme vertreten, der ICS sei als Realisation von weißem Rauschen anzusehen.

Weitergehende Informationen über die autokorrelative Struktur des ICS lassen sich aus den in Tabelle 30 ausgewiesenen Autokorrelationen und partiellen Autokorrelationen gewinnen. Das Autokorrelogramm der Originalwerte deutet auf Nichtstationarität hin. Die Autokorrelationen sinken nur verzögert von dem hohen Anfangsniveau ab; sie sind noch für Lag $k = 12$ mehr als zwei Standardfehler von null entfernt.

Hingegen geben die Autokorrelationen der ersten Differenzen keinen Anlaß zu der Vermutung, $(1 - B)^1 ICS_t$ sei nichtstationär. Die $r_{zz}(k)$ sind relativ flach über den gesamten ausgewiesenen Lag-Bereich verteilt, mit vereinzelt Gipfeln, die jedoch nicht häufig und nicht hoch genug sind, um die Annahme der Nichtstationarität zu rechtfertigen. Einmaliges Differenzieren des ICS reicht demnach aus, eine stationäre Reihe zu produzieren.

2. CD_t und CA_t

Die Zeitreihennatur von CD_t und CA_t kann als miteinander verwandt angesehen werden; die folgenden Ausführungen beziehen sich daher auf beide Reihen.

Erste Hinweise auf die autokorrelative Struktur von CD_t und CA_t lassen sich aus der Betrachtung der Originalwerte gewinnen (vgl. Zeichnung 25). Offensichtlich müssen CD_t und CA_t jeweils als Realisationen nichtstationärer Prozesse angese-

Tabelle 30

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für

ICS

t


Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.91	.81	.68	.56	.45	.37	.29	.22	.19	.18	.22	.26	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.30	.33	.33	.32	.27	.23	.17	.12	.06	.00	-.05	-.08	.27

(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.06	.20	-.07	.00	-.16	.02	-.10	-.20	-.14	-.22	-.07	.00	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.09	.12	.04	.18	-.02	.12	-.01	.06	-.02	.00	-.21	-.08	.12

(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.91	-.10	-.22	-.01	-.01	.09	.10	-.02	.20	.08			.10

(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.06	.20	-.10	-.04	-.13	.04	-.05	-.25	-.11	-.18			.11



Legende:

CD : CD_t

CA : CA_t

CD_t und CA_t sind für die Zahl der Familien sowie saisonal adjustiert.

Consumer durable goods expenditures in quarter t in thousands of constant dollars of 1972;
 Consumer expenditures on motor vehicles and parts in quarter t in thousands of constant dollars of 1972.

hen werden, denn das trendhafte Verhalten der Originalwerte deutet nicht auf die Existenz fester Mittelwerte und finiter Varianzen hin. Wiederum kann das positive Realwachstum der US-Wirtschaft im Untersuchungszeitraum für das nichtstationäre Erscheinungsbild von CD_t und CA_t verantwortlich gemacht werden.

Die Tabellen 31 und 32 enthalten die Autokorrelationen und partiellen Autokorrelationen für CD_t und CA_t . Die Vermutung der Nichtstationarität wird aufgrund des Erscheinungsbildes der Autokorrelationen der Originalwerte bestätigt. Die $r_{zz}(k)$ verharren lange auf hohem Niveau und sinken nur zögernd ab. Dieser deutliche Hinweis auf nichtstationäres Verhalten wird unterstützt durch den hohen Wert des partiellen Autokorrelationskoeffizienten für Lag $k = 1$ (jeweils .91).

Die einmalige Anwendung des Differenzen-Operators produziert jedoch ein Autokorrelogramm, das die Realisation eines stationären stochastischen Prozesses beschreibt. Die Autokorrelationen von CD_t und CA_t folgen jeweils stationären Gesetzmäßigkeiten.

3. $YDQU_t$, $UNRA_t$, $WOWE_t$, $HOUSE_t$, $IMPR_t$, SPI_t , $CAPA_t$ und $ACLA_t$

Die Tabellen 33 bis 40 weisen die Autokorrelationen und partiellen Autokorrelationen von $YDQU_t$, $UNRA_t$, $WOWE_t$, $HOUSE_t$, $IMPR_t$, SPI_t , $CAPA_t$ und $ACLA_t$ aus.

Das Erscheinungsbild des Autokorrelogramms der Originalwerte ist für alle Serien ähnlich: die Autokorrelationen beginnen auf relativ hohem Niveau und sinken nicht schnell genug

Tabelle 31

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürCD
t

Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.96	.92	.88	.84	.81	.79	.77	.75	.73	.71	.69	.66	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.63	.60	.56	.52	.48	.43	.39	.35	.31	.28	.25	.23	.41
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.07	.13	.05	-.08	-.11	.01	-.20	-.18	-.20	.00	-.10	.03	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.07	-.04	.06	.19	.03	.12	-.07	.03	-.07	-.06	-.13	.00	.12
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.96	-.05	-.07	.05	.06	.12	.01	.07	-.15	.07			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.07	.12	.03	-.11	-.11	.05	-.17	-.18	-.18	.07			.11

Tabelle 32

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für CA_t

Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.91	.83	.73	.65	.60	.58	.55	.55	.54	.54	.55	.57	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.56	.54	.50	.47	.43	.38	.31	.26	.20	.16	.14	.14	.34
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	-.09	.11	.00	-.11	-.12	.04	-.13	-.16	-.14	-.05	-.11	.09	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.06	.00	.03	.14	-.01	.13	-.08	.13	-.11	-.04	-.14	.05	.12
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.91	.02	-.12	.04	.10	.17	-.03	.10	.00	.13			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	-.09	.10	.02	-.12	-.15	.05	-.09	-.21	-.20	-.06			.11

Tabelle 33

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für

YDQU

Sample-Periode: 1954.1 - 1976.3

Differenzen-
filterStandard-
fehler

12

11

10

9

8

7

6

5

4

3

2

1

k

 $(1 - B)^0$ $r_{zz}(k)$

.97

.95

.92

.89

.86

.84

.82

.79

.77

.75

.72

.69

.65

.62

.58

.55

.51

.47

.44

.41

.38

.34

.31

.27

.24

.23

.22

.21

.20

.19

.18

.17

.16

.15

.14

.13

.12

.11

.10

.09

.08

.07

.06

.05

.04

.03

.02

.01

.00

-.01

-.02

-.03

-.04

-.05

-.06

-.07

-.08

-.09

-.10

-.11

-.12

-.13

-.14

-.15

-.16

-.17

-.18

-.19

-.20

-.21

-.22

-.23

-.24

-.25

-.26

-.27

-.28

-.29

-.30

-.31

-.32

-.33

-.34

-.35

-.36

-.37

-.38

-.39

-.40

-.41

-.42

-.43

-.44

-.45

-.46

-.47

-.48

-.49

-.50

-.51

-.52

-.53

-.54

-.55

-.56

-.57

-.58

-.59

-.60

-.61

-.62

-.63

-.64

-.65

-.66

-.67

-.68

-.69

-.70

-.71

-.72

-.73

-.74

-.75

-.76

-.77

-.78

-.79

-.80

-.81

-.82

-.83

-.84

-.85

-.86

-.87

-.88

-.89

-.90

-.91

-.92

-.93

-.94

-.95

-.96

-.97

-.98

-.99

-1.00

-1.01

-1.02

-1.03

-1.04

-1.05

-1.06

-1.07

-1.08

-1.09

-1.10

-1.11

-1.12

-1.13

-1.14

-1.15

-1.16

-1.17

-1.18

-1.19

-1.20

-1.21

-1.22

-1.23

-1.24

-1.25

-1.26

-1.27

-1.28

-1.29

-1.30

-1.31

-1.32

-1.33

-1.34

-1.35

-1.36

-1.37

-1.38

-1.39

-1.40

-1.41

-1.42

-1.43

-1.44

-1.45

-1.46

-1.47

-1.48

-1.49

-1.50

-1.51

-1.52

-1.53

-1.54

-1.55

-1.56

-1.57

-1.58

-1.59

-1.60

-1.61

-1.62

-1.63

-1.64

-1.65

-1.66

-1.67

-1.68

-1.69

-1.70

-1.71

-1.72

-1.73

-1.74

-1.75

-1.76

-1.77

-1.78

-1.79

-1.80

-1.81

-1.82

-1.83

-1.84

-1.85

-1.86

-1.87

-1.88

-1.89

-1.90

-1.91

-1.92

-1.93

-1.94

-1.95

-1.96

-1.97

-1.98

-1.99

-2.00

-2.01

-2.02

-2.03

-2.04

-2.05

-2.06

-2.07

-2.08

-2.09

-2.10

-2.11

-2.12

-2.13

-2.14

-2.15

-2.16

-2.17

-2.18

-2.19

-2.20

-2.21

-2.22

-2.23

-2.24

-2.25

-2.26

-2.27

-2.28

-2.29

-2.30

-2.31

-2.32

-2.33

-2.34

-2.35

-2.36

-2.37

-2.38

-2.39

-2.40

-2.41

-2.42

-2.43

-2.44

-2.45

-2.46

-2.47

-2.48

-2.49

-2.50

-2.51

-2.52

-2.53

-2.54

-2.55

-2.56

-2.57

-2.58

-2.59

-2.60

-2.61

-2.62

-2.63

-2.64

-2.65

-2.66

-2.67

-2.68

-2.69

-2.70

-2.71

-2.72

-2.73

-2.74

-2.75

-2.76

-2.77

-2.78

-2.79

-2.80

-2.81

-2.82

-2.83

-2.84

-2.85

-2.86

-2.87

-2.88

-2.89

-2.90

-2.91

-2.92

-2.93

-2.94

-2.95

-2.96

-2.97

-2.98

-2.99

-3.00

-3.01

-3.02

-3.03

-3.04

-3.05

-3.06

-3.07

-3.08

-3.09

-3.10

-3.11

Tabelle 34

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für

UNRA

Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.92	.78	.63	.47	.34	.23	.14	.08	.06	.07	.07	.10	
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.07	.07	.06	.04	.00	-.04	-.10	-.16	-.23	-.29	-.34	-.38	.25
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.59	.16	-.14	-.28	-.20	-.10	-.09	-.18	-.11	.01	.04	.11	
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.03	.01	.03	.11	.09	.07	.02	.02	-.03	-.09	-.11	-.12	.15
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.92	-.45	-.07	-.05	.09	-.11	.03	.09	.12	-.06			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.59	-.30	-.14	-.12	.09	-.09	-.13	-.19	.15	.00			.11

Tabelle 35

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürWOME_t

Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.88	.69	.50	.31	.18	.09	.04	.02	.04	.08	.12	.15	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.19	.20	.17	.10	.03	-.06	-.14	-.22	-.27	-.28	-.24	-.18	.22
(1 - B) ¹	$r_{zz}(k)$	.34	.00	.02	-.19	-.23	-.18	-.09	-.16	-.16	.07	.03	-.05	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.11	.19	.08	-.03	.05	.04	.00	-.08	-.18	-.23	-.14	.08	.13
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.88	-.39	.01	-.18	.16	-.04	.05	-.01	.11	.06			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.34	-.13	.07	-.26	-.07	-.14	.03	-.23	-.10	.07			.11

Tabelle 36

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürHOUSE_t

Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.94	.82	.66	.49	.34	.18	.03	-.09	-.17	-.22	-.24	-.23	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	-.20	-.17	-.13	-.11	-.11	-.11	-.12	-.13	-.14	-.16	-.17	-.17	.26
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.49	.33	.07	-.07	.02	-.14	-.21	-.28	-.32	-.24	-.22	-.19	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	-.04	-.02	.13	.13	.06	.07	.00	.05	.01	-.05	-.08	-.22	.16
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.94	-.52	-.22	.06	.00	-.30	.08	.08	.00	.01			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.49	.11	-.18	-.10	.17	-.22	-.19	-.07	-.10	-.09			.11

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für
1937/1

Sample-Periode: 1954.1 - 1976.3

Differenzen-
filter

filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	r _{zz} (k)	.95	.91	.86	.81	.76	.71	.66	.62	.58	.54	.50	.47	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	r _{zz} (k)	.44	.41	.39	.36	.34	.31	.28	.26	.23	.21	.19	.16	.37
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	r _{zz} (k)	.08	.81	.70	.68	.59	.52	.46	.37	.31	.30	.26	.24	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
(1 - B) ²	r _{zz} (k)	.24	.23	.21	.22	.21	.19	.20	.18	.18	.17	.17	.12	.31
	k	1	2	3	4	5	6	7	8	9	10	11	12	
	r _{zz} (k)	-.28	-.11	.25	-.06	-.02	-.14	.10	-.13	-.18	.12	-.06	.00	.11
(1 - B) ³	k	13	14	15	16	17	18	19	20	21	22	23	24	
	r _{zz} (k)	.00	.04	-.05	.06	.02	-.11	.12	-.07	.03	.03	.01	.02	.13
	k	1	2	3	4	5	6	7	8	9	10			
(1 - B) ⁴	a _{kk}	.95	.91	.86	.81	.76	.71	.66	.62	.58	.54	.50	.47	.10
	k	1	2	3	4	5	6	7	8	9	10			
	a _{kk}	.80	.18	.19	-.25	-.10	-.06	.07	-.14	.05	.19			.11
(1 - B) ⁵	k	1	2	3	4	5	6	7	8	9	10			
	a _{kk}	-.28	-.20	.17	.06	.03	.22	-.01	-.16	-.21	-.07			.11

Tabelle 38

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für $\frac{SPI}{t}$

Sample-Periode: 1954.1 - 1976.3

Differenzen-
filter

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.95	.88	.83	.78	.73	.69	.66	.65	.64	.63	.62	.60	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.58	.56	.54	.51	.47	.42	.37	.33	.29	.25	.21	.18	.38
(1 - B) ¹	$r_{zz}(k)$	.38	-.05	-.09	.00	-.07	-.14	-.24	-.24	-.08	-.12	-.07	.05	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	-.07	-.11	.15	.30	.25	.09	-.03	.02	.05	-.02	-.15	-.15	.14
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.95	-.15	.02	.07	-.02	.01	.13	.10	.04	-.03			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.38	-.24	.03	.02	-.12	-.07	-.20	-.13	.01	-.23			.11

Tabelle 39

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) für

CAPIA t

Sample-Periode: 1954.1 - 1976.3

Differenzen-
filter

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$(1 - B)^0$	$r_{zz}(k)$	.90	.71	.52	.35	.21	.11	.02	-.05	-.07	-.06	-.04	-.01	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.02	.02	.02	.00	-.03	-.08	-.14	-.20	-.26	-.30	-.30	-.28	.22
$(1 - B)^1$	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.41	-.03	-.06	-.19	-.16	-.06	-.07	-.21	-.16	-.03	-.06	.01	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.11	.03	.03	.04	.09	.03	.01	.04	-.11	-.19	-.15	-.03	.13
$(1 - B)^0$	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.90	-.49	.11	-.18	.15	-.16	-.02	.01	.15	-.06			.10
$(1 - B)^1$	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.41	-.24	.08	-.25	.05	-.07	-.05	-.26	.02	-.07			.11

Tabelle 40

Autokorrelationen ($r_{zz}(k)$) und partielle Autokorrelationen (a_{kk}) fürACIA_t

Sample-Periode: 1954.1 - 1976.3

Differenzen- filter	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
(1 - B) ⁰	$r_{zz}(k)$	.85	.62	.41	.23	.13	.11	.09	.08	.10	.13	.17	.22	.10
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.26	.28	.29	.26	.21	.14	.09	.02	.03	.05	.06	.03	.21
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10	11	12	
	$r_{zz}(k)$	.31	.00	-.06	-.25	-.30	-.03	-.02	-.15	-.04	-.02	-.02	-.03	.11
	k	13	14	15	16	17	18	19	20	21	22	23	24	
	$r_{zz}(k)$	.08	-.02	.03	.06	.10	.07	.07	-.02	-.12	-.09	-.17	-.06	.13
(1 - B) ⁰	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.85	-.34	-.03	-.05	.11	.11	-.14	.07	.08	.07			.10
(1 - B) ¹	k	1	2	3	4	5	6	7	8	9	10			
	a_{kk}	.31	-.10	-.04	-.24	-.17	.10	-.09	-.22	-.05	-.06			.11

ab. um Stationarität des jeweils zugrundeliegenden Prozesses zu indizieren. Bei einigen Reihen ($UNRA_t$, $WOWE_t$, $HOUSE_t$, $CAPA_t$ und $ACLA_t$) scheinen die Autokorrelationen zunächst für kleine Lags zügig abzusinken; tatsächlich wird jedoch die 0-Achse nur gekreuzt, oder das Autokorrelogramm schwingt wieder aufwärts, und für mittlere und höhere Lags ergeben sich erneut beachtliche Autokorrelationen.

Es empfiehlt sich demnach in allen Fällen, die Autokorrelationen der ersten Differenzen zu betrachten. Tatsächlich sind die ersten Differenzen aller Reihen - mit Ausnahme derer von $IMPR_t$ - als Realisationen stationärer Prozesse anzusehen, denn die Autokorrelogramme der mithilfe des Differenzen-Operators $(1 - B)^1$ gefilterten Originalwerte sind durch schnelles Absinken der Koeffizienten für kleine Lags gekennzeichnet. Bei der Suche nach Gründen für das verbreitete Phänomen der Nichtstationarität kann zunächst wieder auf das positive Realwachstum der US-Wirtschaft im Untersuchungszeitraum verwiesen werden. Ferner könnte ein Random Walk-Verhalten für Index-Reihen als typisch angesehen werden. Solange sich eine Index-Reihe auf einem bestimmten Niveau befindet, sind stationäre, nicht notwendig unkorrelierte Zufallsschwankungen um den temporären Mittelwert zu beobachten. Nichtstationarität wird induziert, wenn die Reihe dieses Niveau verläßt und sich auf ein neues Niveau begibt, auf dem sie wiederum für einige Zeit verweilt.

Für $IMPR_t$ reicht einmaliges Differenzieren nicht aus, Stationarität zu erzeugen, denn das Autokorrelogramm der ersten Differenzen ist nur unwesentlich von dem der Originalwerte verschieden: auf hohem Niveau beginnend, sinken die Koeffizienten nur sehr zögernd zur 0-Achse hin ab.

Die zweimalige Anwendung des Differenzen-Operators produziert jedoch eine Reihe, deren Autokorrelogramm dem der Realisation eines stationären Prozesses entspricht. Nach Lag $k = 3$ liegen die Autokorrelationen relativ nahe bei null, und auch die partiellen Autokorrelationen rechtfertigen die Annahme der Stationarität für die zweiten Differenzen der Originalwerte. Offensichtlich ist das fast kontinuierlich zunehmende Wachstum der Inflationsrate im Untersuchungszeitraum für die Form der Nichtstationarität der Originalwerte und der ersten Differenzen verantwortlich.

56112 Identifikation der Ordnung (p,q)

1. ICS_t

Es ist zweifelhaft, ob die ersten Differenzen des ICS als Realisation von weißem Rauschen anzusehen sind. $r_{zz}(2)$, $r_{zz}(8)$ und $r_{zz}(10)$ liegen ca. zwei Standardfehler von null entfernt, und auch $r_{zz}(23)$ ist noch relativ groß. Allerdings sollte nicht jeder Besonderheit des Autokorrelogramms Aufmerksamkeit geschenkt werden. So erscheint es zweckmäßig, die Gipfel der Autokorrelationen der ersten Differenzen des ICS für Lags $k = 8, 10, 23$ als Stichprobenvariation, also nicht als unveränderliche Kennzeichen des zugrundeliegenden stochastischen Prozesses zu interpretieren. Es fiel jedenfalls schwer, Gründe für eine Korrelation zwischen den ersten Differenzen des ICS mit einem zeitlichen Abstand von ca. 2 Jahren zu benennen.

Dagegen sollte der für $k = 2$ gemessene Koeffizient bei der Identifikation eines ARIMA-Modells berücksichtigt werden. Veränderungen des ICS könnten kurzfristig durchaus positiv korreliert sein. Da das Autokorrelogramm von $(1 - B)ICS_t$ nicht auf einen autoregressiven Prozeß hindeutet, ist die Identifi-

kation eines Moving Average-Prozesses zweiter Ordnung (MA(2)-Prozeß), dessen erster Parameter null sei, vertretbar. Die Autokorrelationen eines MA(2)-Prozesses sind für Lags $k \geq 3$ null; dies entspricht den obigen Ausführungen in bezug auf die Bedeutung der für Lags $k = 8, 10, 23$ gemessenen Koeffizienten.

2. CD_t und CA_t

Offensichtlich entfernt die einmalige Differenzenbildung nicht nur die Nichtstationarität aus den Originalwerten; sie sorgt auch für Reihen, die nicht von Realisationen von weißem Rauschen zu unterscheiden sind. Keine Autokorrelation weicht signifikant von null ab (Irrtumswahrscheinlichkeit .05).¹⁾ Auch die partiellen Autokorrelationen liegen alle im nichtsignifikanten Bereich (Irrtumswahrscheinlichkeit .05).

Aufgrund dieses Sachverhalts ist die Identifikation eines Random Walk-Modells für CD_t bzw. CA_t gerechtfertigt.

3. $YDQU_t$

Das Autokorrelogramm der ersten Differenzen gibt keine Hinweise auf nennenswerte autokorrelative Strukturen. Die Ver-

- 1) Das Autokorrelogramm der ersten Differenzen von $CDM_{t+1,t+2}$ bzw. $CAM_{t+1,t+2}$ (vgl. Tabellen 7 und 8) weist jeweils für Lags $k = 4$ relativ hohe Werte aus, die dann auch bei der Identifikation und Schätzung univariater ARIMA-Modelle berücksichtigt sind (vgl. Abschnitt 4.5.2.1). Da $CDM_{t+1,t+2}$ ($CAM_{t+1,t+2}$) und CD_t (CA_t) verbunden sind durch die Beziehung:

$$CDM_{t+1,t+2} = CD_{t+1} + CD_{t+2}$$

bzw.

$$CAM_{t+1,t+2} = CA_{t+1} + CA_{t+2}$$

sollte sich der für $CDM_{t+1,t+2}$ ($CAM_{t+1,t+2}$) aufgedeckte saisonale Faktor auch bei CD_t (CA_t) wiederfinden lassen.

Die Autokorrelogramme von $CDM_{t+1,t+2}$ ($CAM_{t+1,t+2}$) und CD_t (CA_t) beziehen sich jedoch auf unterschiedlich lange

Sample-Perioden, so daß eine Veränderung des saisonalen Adjustierungsmechanismus für das Absinken der Autokorrelation für Lag $k = 4$ verantwortlich sein könnte.

mutung liegt nahe, daß einmaliges Differenzieren von $YDQU_t$ eine Reihe produziert, die als Realisation von weißem Rauschen anzusehen ist. Zwar weist das Autokorrelogramm der ersten Differenzen von $YDQU_t$ noch vereinzelte kleine Gipfel auf; ihre Existenz scheint aber eher Zufallseinflüssen als unveränderlichen Kennzeichen des zugrundeliegenden stochastischen Prozesses zuweisbar zu sein. Das identifizierte ARIMA-Modell beschreibt daher einen Random Walk-Prozeß.

4. $UNRA_t$

Die Autokorrelationen der ersten Differenzen von $UNRA_t$ fallen nach dem hohen Wert für Lag $k = 1$ schnell in den negativen Bereich ab, wo sie für Lag $k = 4$ einen Gipfel von $-.28$ besitzen. Danach nähern sich die Autokorrelationen wieder der 0-Achse und kreuzen sie bei Lag $k = 10$. Ab Lag $k = 11$ verbleiben die $r_{zz}(k)$ auf niedrigem Niveau bis zum Lag $k = 20$ im positiven Bereich, um dann wieder negative Werte anzunehmen.

Falls das schwingungsähnliche Verhalten der Autokorrelationen unberücksichtigt bleibt - was mit den relativ geringen Ausschlägen gerechtfertigt werden könnte -, würde sich für die ersten Differenzen von $UNRA_t$ ein Moving Average-Modell erster Ordnung empfehlen, dessen theoretische Autokorrelationen null sind für Lags $k \geq 2$. Wenn hingegen die Autokorrelationen nach Lag $k = 1$ als nicht rein zufällig von null abweichend angesehen werden, könnte sich ein höherwertiges autoregressives Modell mit negativen und/oder konjugiert komplexen Wurzeln anbieten, die für ein schwingungsförmiges Autokorrelogramm sorgen. Die signifikanten partiellen Autokorrelationen für Lags $k = 1, 2$ deuten auf ein autoregressives Modell zweiter Ordnung hin.

5. $WOWE_t$

Die Autokorrelationen der ersten Differenzen von $WOWE_t$ sinken nach Lag $k = 1$ zur 0-Achse ab und verweilen dann für einige Lags im negativen Bereich, mit Gipfeln um Lags $k = 4, 5, 6$. Von Lag $k = 10$ an sind die Autokorrelationen überwiegend positiv, um ab Lag $k = 20$ wieder negative Werte anzunehmen.

Für das Verhalten der Autokorrelationen der ersten Differenzen für Lags $k = 1, 2, 3$ könnte ein Moving Average-Modell erster Ordnung eine adäquate Beschreibung sein, denn das abrupte Absinken der Autokorrelationen für Lag $k \geq (q + 1)$ ist das Kennzeichen eines Moving Average-Modells der Ordnung q .

Die Schwingungen der Autokorrelationen sind schwieriger zu interpretieren. Signifikante partielle Autokorrelationen für Lags $k = 4, 8$ lassen einen saisonalen Faktor mit einer saisonalen Spanne von einem Jahr vermuten. Es ist hier schwer feststellbar, ob ein saisonales autoregressives oder Moving Average-Modell angebracht ist.

6. $HOUSE_t$

Die Autokorrelationen der ersten Differenzen beginnen mit .49 für Lag $k = 1$ auf relativ hohem Niveau und sinken dann in einer fast geometrisch gedämpften Form zur 0-Achse ab. Zwischen Lag $k = 6$ und $k = 12$ nehmen die Autokorrelationen negative Werte an, mit Gipfeln von $-.28$ und $-.32$ für Lags $k = 8, 9$.

Der erste Teil des Autokorrelogramms erinnert an das Verhalten der Autokorrelationen eines autoregressiven Prozesses

erster Ordnung, dessen Parameter positiv (und kleiner als eins) ist. Die Autokorrelationen dieses Prozesses sinken geometrisch gedämpft zur 0-Achse ab.

Die negative Schwingung der Autokorrelationen zwischen Lag $k = 6$ und $k = 12$ ist nicht einfach zu interpretieren. Die naheliegendste Vermutung ist, daß die ersten Differenzen des zugrundeliegenden Prozesses ein saisonales Element mit einer saisonalen Spanne von ca. 1.5 bis 2.5 Jahren besitzen; das relativ gleichförmige Erscheinungsbild könnte ein Reflex der Kovarianz der $r_{zz}(k)$ sein. Ob ein saisonaler autoregressiver oder Moving Average-Parameter besser geeignet ist, diese saisonale Komponente zu beschreiben, ist hier nicht festzustellen. Einen ersten Hinweis auf die saisonale Spanne geben die partiellen Autokorrelationen, die nach Lag $k = 1$ nur für Lag $k = 6$ einen signifikanten Wert aufweisen.

7. $IMPR_t$

Das Autokorrelogramm der zweiten Differenzen von $IMPR_t$ scheint nur wenig autokorrelative Struktur zu besitzen. Nennenswerte Autokorrelationen sind nur für Lags $k = 1, 3$ zu entdecken; das Erscheinungsbild des Autokorrelogramms bis in mittlere Lag-Bereiche hinein kann mit einigen Zweifeln als von gedämpft sinusförmigen Schwingungen gekennzeichnet beschrieben werden.

Es ist möglich, daß die negativen Autokorrelationen für Lags $k = 1, 2$ der zweifachen Anwendung des Differenzen-Operators zuzuweisen sind. Vielleicht würde ein autoregressives Modell erster Ordnung für die ersten Differenzen mit einem autoregressiven Parameter um .80 ausreichen, um eine weißem Rau-

schen ähnliche Reihe zu erzeugen; die Identifikation eines eventuell zu häufig differenzierten Modells ist jedoch der eines möglicherweise nichtstationären Modells vorzuziehen.¹⁾ Aufgrund der partiellen Autokorrelationen scheint ein autoregressives Modell erster oder zweiter Ordnung am ehesten geeignet zu sein, die autokorrelative Struktur der zweiten Differenzen von $IMPR_t$ zu erfassen.

8. SPI_t

Das Erscheinungsbild des Autokorrelogramms der ersten Differenzen von SPI_t weist auf ein Moving Average-Modell erster Ordnung oder ein autoregressives Modell zweiter Ordnung hin. Für ein Moving Average-Modell erster Ordnung spricht das abrupte Absinken der Autokorrelationen nach Lag $k = 1$ und das oszillierende Verhalten der partiellen Autokorrelationen für kleine Lags. Ein autoregressives Modell zweiter Ordnung erscheint plausibel, wenn die negative Schwingung der Autokorrelationen bis in mittlere Lags berücksichtigt wird.

9. $CAPA_t$

Das Autokorrelogramm der ersten Differenzen von $CAPA_t$ beginnt mit .41 auf relativ hohem Niveau und sinkt dann sofort in den negativen Bereich ab, in dem es für mehrere Lags verweilt. Wie bei SPI_t lassen sich plausible Gründe für die Identifikation eines Moving Average-Modells erster Ordnung wie für die eines autoregressiven Modells zweiter Ordnung, jeweils für die ersten Differenzen, finden. Das abrupte Absinken der Autokorrelationen für Lag $k = 2$ deutet auf ein Moving Average-Modell erster Ordnung, während das längere Verweilen der $r_{zz}(k)$

1) Nach Granger/Newbold spricht die Erfahrung dafür, bei Zweifeln über die erforderliche Zahl sukzessiver Differenzen sich für die höhere Zahl zu entscheiden: "... our experience in analyzing a large number of economic time series has convinced us that, in those situations where the degree of differencing has been in doubt, it is generally the case that superior forecasts are obtained when the difference operator in question is included in the model". Granger/Newbold (1977), S. 102.

im negativen Bereich ein sinusförmiges Verhalten der theoretischen Autokorrelationen eines autoregressiven Prozesses reflektieren könnte. Das für einen Moving Average-Prozeß typische oszillierende Verhalten der partiellen Autokorrelationen ist hier bis Lag $k = 6$ besonders ausgeprägt.

10. $ACLA_t$

Das Autokorrelogramm der ersten Differenzen von $ACLA_t$ weist bis ca. Lag $k = 7$ eine langgestreckte Schwingung auf, die auf ein höherwertiges autoregressives Modell hindeutet. Der negative Gipfel um Lag $k = 4, 5$ könnte das Ergebnis einer nicht voll befriedigenden saisonalen Adjustierung sein. Tatsächlich lassen sich keine stichhaltigen ökonomischen Begründungen für eine negative Autokorrelation mit einer saisonalen Spanne von vier Quartalen geben.

Die partiellen Autokorrelationen besitzen für Lags $k = 1, 4$ signifikante Werte, was die Identifikation eines saisonalen ARIMA-Modells mit einer saisonalen Spanne von vier Quartalen für $ACLA_t$ nahelegt.

5612 Schätzung und Diagnostic Checks

Tabelle 41 weist die Ergebnisse der Schätzung der univariaten ARIMA-Modelle sowie die Statistik Q zusammen mit den auf die jeweilige Zahl der Freiheitsgrade bezogenen kritischen Werte der Chi-Quadrat-Verteilung (Irrtumswahrscheinlichkeiten .05 und .10) aus. Zusätzliche Erkenntnisse über die Adäquanz der identifizierten und geschätzten univariaten ARIMA-Modelle vermitteln die Tabellen 42 bis 49, die die jeweiligen $r_{\hat{u}\hat{u}}(k)$ und $r_{\hat{u}\hat{z}}(k)$ aufführen.¹⁾

1) Zur Definition der $r_{\hat{u}\hat{u}}(k)$ und $r_{\hat{u}\hat{z}}(k)$ vgl. Abschnitt 4234.

Die $r_{\hat{u}\hat{u}}(k)$ und $r_{\hat{u}\hat{z}}(k)$ von CD_t , CA_t und $YDQU_t$ sind nicht ausgewiesen, da für Random Walk-Modelle gilt:

$$r_{zz}(k) = r_{\hat{u}\hat{u}}(k) = r_{\hat{u}\hat{z}}(-k) \quad k > 0$$

Die z_t beziehen sich auf die d-fach differenzierte Reihe.

Ergebnisse der Schätzung des univariante ARIMA-Modells für ICS_t , CD_t , CA_t , $YDQU_t$, $UNRA_t$, $WOWE_t$, $HOUSE_t$, $IMPR_t$, SPI_t , $CAPA_t$ und $ACIA_t$

(In Klammern: t-Statistik)

Sample-Periode: 1954.1 - 1976.3

Geschätztes ARIMA-Modell

		Q	df	$\chi^2_{.05, df}$	$\chi^2_{.10, df}$
1. ICS_t	$(1 - B)X_t = (1 + .22B^2)U_t$ (2.13)	16.6	23	35.2	32.0
2. CD_t	$(1 - B)X_t = U_t$	23.2	24	36.4	33.2
3. CA_t	$(1 - B)X_t = U_t$	21.0	24	36.4	33.2
4. $YDQU_t$	$(1 - B)X_t = U_t$	21.9	24	36.4	33.2
5. $UNRA_t$	$(1 - .79B + .32B^2)(1 - B)X_t = U_t$ (7.80) (3.11)	16.5	22	33.9	30.8
6. $WOWE_t$	$(1 + .23B^4)(1 - B)X_t = (1 + .35B)U_t$ (2.42) (6.47)	25.9	22	33.9	30.8
7. $HOUSE_t$	$(1 - .52B + .16B^6)(1 - B)X_t = U_t$ (5.63) (2.09)	23.9	22	33.9	30.8
8. $IMPR_t$	$(1 + .34B + .21B^2)(1 - B)^2X_t = U_t$ (3.30) (2.03)	19.4	22	33.9	30.8
9. SPI_t	$(1 - .48B + .24B^2)(1 - B)X_t = U_t$ (4.57) (2.27)	23.1	22	33.9	30.8
10. $CAPA_t$	$(1 - B)X_t = (1 + .66B)U_t$ (8.48)	16.1	23	35.2	32.0
11. $ACIA_t$	$(1 - .30B + .26B^4)(1 - B)X_t = U_t$ (3.02) (2.72)	14.9	22	33.9	30.8

Legende:

df Zahl der Freiheitsgrade.

Zu den Bezeichnungen der Variablen vgl. Tabelle 37.

Tabelle 42

Autokorrelationen ($r_{\hat{a}\hat{a}}(k)$) und Kreuzkorrelationen ($r_{\hat{a}\hat{z}}(k)$) des univariaten ARIMA-Modells für ICS_t

Sample-Periode: 1954.1 - 1976.3

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{a}\hat{a}}(k)$		-.02	-.02	-.04	-.03	-.13	.05	-.08	-.18	-.09	-.19	-.20	-.06	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{a}\hat{a}}(k)$		.11	.01	.00	.14	-.04	.08	-.01	.01	.04	.01	-.20	-.06	.12
k	0	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{a}\hat{z}}(k)$		.96	.01	-.02	-.07	-.04	-.14	.01	.00	-.21	.02	-.18	-.03	.01
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{a}\hat{z}}(k)$		.10	.08	.01	.14	.04	.08	-.02	.03	.00	.02	-.18	-.07	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{a}\hat{z}}(k)$		.02	.19	-.05	.00	-.13	.06	-.03	-.17	-.11	-.23	-.07	-.01	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{a}\hat{z}}(k)$		.09	.04	.02	.16	-.02	.11	.00	.05	.03	.00	-.21	-.07	.11

Tabelle 43

Autokorrelationen ($r_{\hat{a}\hat{a}}(k)$) und Kreuzkorrelationen ($r_{\hat{a}\hat{z}}(k)$) des univariaten ARIMA-Modells fürUNRA $\hat{t}$

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{a}\hat{a}}(k)$	-.07	.07	.00	-.20	-.02	-.05	.09	-.21	-.03	.05	.01	-.01	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{a}\hat{a}}(k)$	.04	.00	-.08	.14	-.03	.09	-.07	.07	-.02	-.07	.03	-.14	.12
k													
	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{a}\hat{z}}(k)$	.76	-.01	.00	-.11	-.16	-.03	-.03	-.07	-.16	.00	.05	.01	.01
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{a}\hat{z}}(k)$	.01	.00	.04	.11	.01	.04	-.01	.03	-.05	-.08	-.06	-.07	
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{a}\hat{z}}(k)$	.55	.24	.04	-.20	-.18	-.12	.02	-.12	-.13	-.02	.03	.03	
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{a}\hat{z}}(k)$	.04	.02	-.05	.07	.04	.09	.01	.03	.01	-.06	-.02	-.11	

Tabelle 44

Autokorrelationen ($r_{\hat{Q}\hat{Q}}(k)$) und Kreuzkorrelationen ($r_{\hat{Q}\hat{Z}}(k)$) des univariaten ARIMA-Modells fürWOWE_t

Sample-Periode: 1954.1 - 1976.3

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{Q}\hat{Q}}(k)$		.01	.01	.11	.01	-.12	-.10	.06	-.15	-.21	.16	.04	-.17	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{Q}\hat{Q}}(k)$		.07	.20	.04	-.15	.04	.04	.02	-.03	-.09	-.15	-.10	.11	.12
k	0	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{Q}\hat{Z}}(k)$		.91	.00	.02	.11	.02	-.10	-.12	.00	-.17	-.19	.09	-.01	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{Q}\hat{Z}}(k)$		.10	.18	.02	-.08	.10	.07	.00	-.10	-.15	-.16	-.07	.12	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{Q}\hat{Z}}(k)$		.31	-.05	.08	-.17	-.22	-.15	-.03	-.13	-.18	.12	.07	-.10	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{Q}\hat{Z}}(k)$		.07	.18	.09	-.08	.00	-.01	.00	.01	-.09	-.18	-.15	.05	.11

Autokorrelationen ($r_{\hat{a}\hat{a}}(k)$) und Kreuzkorrelationen ($r_{\hat{a}z}(k)$) des univariaten ARIMA-Modells fürHOUSE_t

Sample-Periode: 1954.1 - 1976.3

k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{a}\hat{a}}(k)$	-.07	.11	-.14	-.18	.17	.04	.01	-.06	-.16	-.07	-.04	-.19	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{a}\hat{a}}(k)$	.07	-.12	.11	.05	-.06	.01	-.09	.07	.05	.01	.03	-.22	.12
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{a}z}(k)$	.85	-.01	.07	-.10	-.05	.17	.01	-.07	-.15	-.21	-.12	-.11	.15
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{a}z}(k)$	.03	-.05	.11	.04	-.03	.01	-.04	.07	.02	-.03	-.05	-.18	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{a}z}(k)$	.34	.29	.05	-.13	.07	-.08	-.08	-.14	-.20	-.13	-.13	-.19	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{a}z}(k)$	-.03	-.09	.08	.10	.00	.04	-.05	.04	.05	.01	.05	-.18	.11

Tabelle 46

Autokorrelationen ($r_{\hat{u}\hat{u}}(k)$) und Kreuzkorrelationen ($r_{\hat{u}\hat{z}}(k)$) des univariaten ARIMA-Modells für IMPR_t

Sample-Periode: 1954.1 - 1976.3

	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
k													
$r_{\hat{u}\hat{u}}(k)$	.05	.07	.18	-.04	-.05	-.18	-.04	-.22	-.25	.00	-.08	.00	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}\hat{u}}(k)$	-.02	.03	-.02	.05	.02	-.08	.08	-.03					.12
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}\hat{z}}(k)$	.94	.00	.00	.17	.00	.00	-.16	.05	-.14	-.23	.03	-.07	.00
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}\hat{z}}(k)$	-.02	.03	-.04	.05	.04	-.09	.09	-.05	.03	.02	.03	.03	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}\hat{z}}(k)$	-.28	-.04	.24	-.11	-.06	-.14	.02	-.18	-.17	.10	-.07	.01	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}\hat{z}}(k)$	.00	.04	-.03	.05	.01	-.09	.11	-.05	.04	.04	.01	.02	.11

Tabelle 47

Autokorrelationen ($r_{\hat{u}\hat{u}}(k)$) und Kreuzkorrelationen ($r_{\hat{u}z}(k)$) des univariaten ARIMA-Modells fürSPI_t

Sample-Periode: 1954.1 - 1976.3

Standard- fehler													
k	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{u}\hat{u}}(k)$	.01	-.01	-.01	.05	-.10	-.07	-.14	-.23	.05	-.14	-.10	.11	
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}\hat{u}}(k)$	-.04	-.13	.15	.18	.14	.07	-.04	.03	.04	-.01	-.13	-.05	
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}z}(k)$	.90	.00	.00	.03	.03	-.10	-.12	-.21	-.18	-.03	-.15	-.03	.06
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}z}(k)$	-.12	-.07	.20	.23	.15	.04	-.02	.06	.04	-.05	-.13	-.10	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}z}(k)$	.43	-.01	-.12	.00	-.07	-.10	-.16	-.25	-.04	-.09	-.12	.06	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}z}(k)$	.02	-.12	.07	.22	.22	.12	-.03	-.02	.03	.01	-.12	-.10	.11

.11

Tabelle 48

Autokorrelationen ($r_{\hat{u}\hat{u}}(k)$) und Kreuzkorrelationen ($r_{\hat{u}z}(k)$) des univariaten ARIMA-Modells fürCAPA_t

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{u}\hat{u}}(k)$	-.07	-.01	.03	-.16	-.05	-.04	.02	-.17	-.08	.03	-.05	-.03	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}\hat{u}}(k)$	.15	-.07	.08	-.05	.11	-.01	-.04	.12	-.13	-.07	-.11	.02	.11
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}z}(k)$	.82	-.07	.01	-.07	-.17	-.06	-.02	-.08	-.20	-.05	-.01	-.06	.06
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}z}(k)$	.08	-.02	.04	.02	.09	-.03	.03	.03	-.15	-.12	-.09	.02	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}z}(k)$	.51	-.05	.02	-.12	-.14	-.07	.00	-.13	.17	.02	-.03	-.06	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}z}(k)$	.11	.02	.03	.00	.07	.06	-.04	.08	-.05	-.13	-.14	-.05	.11

Tabelle 49

Autokorrelationen ($r_{\hat{u}\hat{u}}(k)$) und Kreuzkorrelationen ($r_{\hat{u}z}(k)$) des univariaten ARIMA-Modells für

ACIA t

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{u}\hat{u}}(k)$	-.03	-.09	.00	.02	-.21	.06	.02	-.21	-.02	-.02	.00	-.08	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}\hat{u}}(k)$	.14	-.05	.04	-.01	.07	.02	.04	.00	.10	.02	-.12	.00	.12
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}z}(k)$	.91	.00	-.09	.01	.02	-.16	.05	-.02	-.19	-.05	-.02	-.04	-.06
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}z}(k)$	.08	-.05	.04	.03	.11	.05	.06	-.03	-.10	-.04	-.14	-.01	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}z}(k)$	.24	.01	.01	-.22	-.32	-.03	.02	-.16	-.01	-.01	.00	-.03	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}z}(k)$	.13	-.01	.03	.02	.04	.03	.03	.01	-.10	-.02	-.13	-.04	.11

Da die Transformation der Reihen nur eine Vorstufe zur Kreuzkorrelogramm-Analyse und zur Identifikation und Schätzung der Transferfunktion-Form ist, seien im folgenden die Ergebnisse der Schätzung und Diagnostic Checks gerafft kommentiert.

1. ICS_t

Offensichtlich transformiert das identifizierte und geschätzte ARIMA-Modell den ICS zu einer Reihe, die als Realisation von weißem Rauschen anzusehen ist, denn die Q-Statistik liegt deutlich unterhalb des kritischen Wertes der Chi-Quadrat-Verteilung (Irrtumswahrscheinlichkeit .10). Insbesondere die Berücksichtigung des Moving Average-Parameters erweist sich als berechtigt, da die ursprünglich recht hohe Autokorrelation von $(1 - B)ICS_t$ für Lag $k = 2$ nunmehr fast verschwunden ist. Auch das Erscheinungsbild der $r_{\hat{u}}(k)$ und $r_{\hat{u}z}(k)$ (vgl. Tabell 42) gibt keinen Anlaß, an der Adäquanz des identifizierten und geschätzten Modells zu zweifeln.¹⁾

2. CD_t und CA_t

Die Annahme eines Random Walk-Modells wird für beide Ausgabebereichen durch den Vergleich der jeweiligen Q-Statistik mit den kritischen Werten der Chi-Quadrat-Verteilung gerechtfertigt. Die Werte von Q liegen klar unterhalb des kritischen

1) Das für den ICS identifizierte und geschätzte, Random Walk-ähnliche Modell ließe sich in Anlehnung an Katona mit dem Prozeß der Bildung und Veränderung von Erwartungen erklären: "When a trend of change in expectations is established, it will be reversed only slowly and gradually - unless major unexpected developments take place. The first part of this proposition is derived from the theorem about the slowness and gradualness of social learning. It takes time, usually at least several months, until news or information different from that prevalent in the preceding period spreads to many people and is reinforced by word of mouth. Therefore, a long-lasting improvement (deterioration) of collective expectations will commonly be followed by a plateau or by insignificant ups and downs before a sustained deterioration (improvement) occurs". Katona (1972), S. 569. Auch die leichte positive Autokorrelation von $(1 - B)ICS_t$ läßt sich mit dieser Aussage begründen; es muß jedoch offen bleiben, warum der für Lag $k = 1$ gemessene Koeffizient nicht größer ist. Möglicherweise wird sich diese Frage bei Vorliegen eines umfangreicheren Samples, in dem sich die Zeitreihennatur des ICS deutlicher ausprägt, beantworten lassen.

Wertes der Chi-Quadrat-Verteilung von 33.2 (Irrtumswahrscheinlichkeit .10). Die ersten Differenzen von CD_t bzw. CA_t können als Realisationen von weißem Rauschen angesehen werden.

3. $YDQU_t$, $UNRA_t$, $WOWE_t$, $HOUSE_t$, $IMPR_t$, SPI_t , $CAPA_t$ und $ACLA_t$

Wie Tabelle 41 zu entnehmen ist, genügen im allgemeinen ARIMA-Modelle niedriger Ordnung - mit $p \leq 2$ oder 4 und $q \leq 1$ -, um den Erzeugungsmechanismus der Reihen zu beschreiben. Eine Ausnahme stellt $HOUSE_t$ dar, dessen autoregressive Ordnung $p = 6$ beträgt. Da der für a_6 geschätzte Wert jedoch recht niedrig liegt und nur knapp signifikant ist, sollte diesem Umstand keine besondere Bedeutung zugewessen werden.

Wie der Q-Test in allen Fällen zeigt, ist die Annahme, die transformierten Reihen seien als Realisationen von weißem Rauschen zu betrachten, gerechtfertigt. Auch aus den Erscheinungsbildern der $r_{\hat{u}\hat{u}}(k)$ und $r_{\hat{u}\hat{z}}(k)$ (vgl. Tabellen 43 - 49) ergeben sich keine Hinweise auf Modell-Inadäquanzen.

562 Kreuzkorrelogramm-Analyse

5621 Allgemeines

Die Kreuzkorrelogramme der mithilfe univariater ARIMA-Modelle transformierten Reihen sind in den Tabellen 50 bis 59 ausgewiesen. Die erste Reihe ($\hat{u}_t$) ist stets die transformierte ICS-Reihe; die zweite Reihe ($\hat{v}_t$) ist die Transformation einer der Variablen CD_t , CA_t , $YDQU_t$, $UNRA_t$, $WOWE_t$, $HOUSE_t$, $IMPR_t$, SPI_t , $CAPA_t$ und $ACLA_t$.

Tabelle 50

Kreuzkorrelationen ($r_{\hat{u}\hat{\phi}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und CD_t ($\hat{\phi}_t$)

Sample-Periode: 1954.1 - 1976.3

k	0	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{\phi}}(k)$														
k	.24	-.05	-.16	-.03	.04	-.23	-.03	-.21	-.11	.05	.01	-.11	-.06	.11
	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{\phi}}(k)$														
k	-.10	.05	.02	.12	.11	-.09	-.07	.03	-.07	.01	-.05	-.05		.11
	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{u}\hat{\phi}}(k)$														
k	.26	.19	.25	-.01	-.05	-.06	.09	-.10	-.11	-.20	-.17	.01		.11
	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{u}\hat{\phi}}(k)$														
k	-.06	-.07	.06	.18	.04	.15	-.06	.11	-.03	-.01	-.12	-.01		.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 51

Kreuzkorrelationen ($r_{\hat{u}\hat{v}}(k)$) der Transformationen von $1CS_t$ ($\hat{u}_t$) und CA_t ($\hat{v}_t$)

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}\hat{v}}(k)$	.24	-.05	-.11	.01	.11	-.22	-.01	-.16	-.11	.06	-.01	-.12	-.07
k	13	14	15	16	17	18	19	20	21	22	23	24	.11
$r_{\hat{u}\hat{v}}(k)$	.10	.03	.03	.14	.13	-.09	-.08	.06	-.09	.01	-.03	-.07	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}\hat{v}}(k)$	.20	.16	.25	-.01	-.08	-.10	-.08	-.12	-.06	-.18	-.16	-.01	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}\hat{v}}(k)$	-.04	-.05	.10	.20	.03	.15	-.11	.09	-.05	.02	-.13	.04	.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 52

Kreuzkorrelationen ($r_{\hat{u}\hat{\varphi}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und $YDQI_t$ ($\hat{\varphi}_t$)

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}\hat{\varphi}}(k)$	.02	.15	-.07	.16	.09	.04	-.10	.04	-.07	.04	.07	-.16	-.02
k	13	14	15	16	17	18	19	20	21	22	23	24	.11
$r_{\hat{u}\hat{\varphi}}(k)$	.02	-.19	-.16	.12	.07	.16	.12	-.08	.05	-.10	.08	-.16	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}\hat{\varphi}}(k)$	.04	.01	.00	.02	.03	.00	.02	.00	.00	-.01	.01	.00	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}\hat{\varphi}}(k)$	-.01	.00	-.02	-.01	.01	.01	.00	.01	.00	.01	.01	.01	.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 53

Kreuzkorrelationen ($r_{\hat{u}\hat{v}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und $UNRA_t$ ($\hat{v}_t$)

Sample-Periode: 1954.1 - 1976.3

k	0	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{v}}(k)$	-.29	.06	.19	.10	.20	.10	.08	-.03	.09	-.06	-.09	-.01	-.07	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{v}}(k)$	.11	-.10	.06	-.10	.03	.00	.09	.01	.01	.03	-.01	.08		.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{u}\hat{v}}(k)$	-.15	-.23	-.02	-.12	.14	-.08	-.16	.06	.02	.06	.11	.10		.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{u}\hat{v}}(k)$	-.10	.03	.02	-.04	.01	-.06	-.07	-.07	-.02	-.02	.07	-.02		.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 54

Kreuzkorrelationen ($r_{\hat{u}\hat{v}}(k)$) der Transformationen von LCS ($\hat{u}_t$) und WOME ($\hat{v}_t$)

Sample-Periode: 1954.1 - 1976.3

k	0	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{v}}(k)$	.25	-.04	-.01	.04	-.17	-.27	.09	-.10	-.08	.01	.10	.01	.04	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{v}}(k)$	.11	-.03	-.01	.02	.07	-.02	-.06	-.02	-.02	-.05	-.05	.08	.11	
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{u}\hat{v}}(k)$	.27	.13	.08	-.08	.02	.01	.05	-.09	.05	-.18	-.13	.02	.11	
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{u}\hat{v}}(k)$	.05	-.02	.00	.07	-.03	.08	.10	.03	-.11	.01	-.07	.00	.11	

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 55

Kreuzkorrelationen ($r_{\hat{u}\hat{\varphi}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und $HOUSE_t$ ($\hat{\varphi}_t$)

Sample-Periode: 1954.1 - 1976.3

k	0	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{\varphi}}(k)$	.22	.24	-.01	-.01	-.12	.18	-.18	-.05	.00	-.27	.05	-.15	-.06	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{\varphi}}(k)$	-.11	.17	-.03	.15	-.07	-.03	.06	.06	.19	-.09	.00	-.22		.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{u}\hat{\varphi}}(k)$	.16	-.01	-.22	-.12	.02	.15	-.17	-.05	-.08	-.26	.05	-.01		.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{u}\hat{\varphi}}(k)$	.11	.03	.02	.06	.04	.00	.05	.08	-.04	.01	-.03	.03		.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 36

Kreuzkorrelationen ($r_{\Delta\phi}(k)$) der Transformationen von $IC5_t$ (Δ_t) und IMH_t (ϕ_t)

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\Delta\phi}(k)$	.06	-.41	-.21	.08	-.19	-.08	.10	.09	-.03	.12	.11	.03	.04
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\Delta\phi}(k)$	-.01	.03	.02	-.14	.07	-.13	.09	.01	-.04	-.21	-.05	.00	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\Delta\phi}(k)$	.09	-.02	-.09	.07	-.08	-.01	.25	.14	.13	-.04	.08	-.14	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\Delta\phi}(k)$	.04	-.05	-.08	-.12	-.01	-.15	-.02	.01	.02	.09	.02	.04	.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 57

Kreuzkorrelationen ($r_{\hat{u}\hat{v}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und SPI_t ($\hat{v}_t$)

Sample-Periode: 1954.1 - 1976.3

k	0	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{v}}(k)$	.23	.23	.01	.18	-.09	-.15	.08	-.02	-.20	-.14	-.01	.02	.01	.11
k		13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{u}\hat{v}}(k)$	.15	.04	-.08	.17	.03	.16	-.12	.00	-.13	.16	-.19	-.07	.11	
k		-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}\hat{v}}(k)$	.07	.02	.21	-.11	-.10	-.15	-.05	-.07	.00	-.18	-.08	-.05	.11	
k		-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}\hat{v}}(k)$	-.06	.11	.08	.11	.03	.02	.02	.02	-.10	.06	.00	-.03	.11	

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 58

Kreuzkorrelationen ($r_{\hat{u}\hat{v}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und $CAPA_t$ ($\hat{v}_t$)

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{u}\hat{v}}(k)$	.33	-.05	-.21	.00	-.10	-.21	-.02	-.02	-.11	.10	.02	.03	.01
k	13	14	15	16	17	18	19	20	21	22	23	24	.11
$r_{\hat{u}\hat{v}}(k)$	.09	-.07	.14	-.03	.06	-.02	-.04	-.01	-.08	-.02	-.03	.10	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{u}\hat{v}}(k)$	.25	.12	.08	.06	-.14	.05	.14	-.14	.03	-.10	-.17	.00	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{u}\hat{v}}(k)$	.07	-.15	.04	.06	.00	.04	.10	.00	.01	.05	-.16	.00	.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 59

Kreuzkorrelationen ($r_{\hat{u}\hat{v}}(k)$) der Transformationen von ICS_t ($\hat{u}_t$) und $ACLA_t$ ($\hat{v}_t$)

Sample-Periode: 1954.1 - 1976.3

k	0	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{u}\hat{v}}(k)$	.41	-.02	-.10	-.03	-.06	-.26	.00	-.03	-.21	.11	.03	.03	.05	.11
k	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{u}\hat{v}}(k)$	.10	-.08	.06	.02	-.03	.03	-.01	.00	.06	.04	-.15	.04		.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{u}\hat{v}}(k)$	.17	-.04	.12	-.09	-.02	.06	.27	-.22	.00	-.13	-.12	.07		.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{u}\hat{v}}(k)$	.01	-.10	.05	.10	-.08	.10	.09	.03	-.02	-.01	-.10	.02		.11

Zu den zur Transformation verwendeten univariaten ARIMA-Modellen vgl. Tabelle 41.

Tabelle 60

 Ergebnisse des S_K -Tests ausgewählter Kausalmuster

Sample-Periode: 1954.1 - 1976.3

Kausalmuster	S_K	df	$\chi^2_{.05, df}$	$\chi^2_{.10, df}$
ICS — CD	37.0 ^{**}	24	36.4	33.2
CD — ICS	21.9	24	36.4	33.2
ICS $\equiv$ CD	64.1	49	67.5	63.2
ICS — CA	34.7 [*]	24	36.4	33.2
CA — ICS	22.7	24	36.4	33.2
ICS $\equiv$ CA	62.6	49	67.5	63.2
ICS — YDQU	.4	24	36.4	33.2
YDQU — ICS	30.1	24	36.4	33.2
ICS $\equiv$ YDQU	30.6	49	67.5	63.2
ICS — UNRA	20.1	24	36.4	33.2
UNRA — ICS	18.6	24	36.4	33.2
ICS $\equiv$ UNRA	46.1	49	67.5	63.2
ICS — WOVE	20.4	24	36.4	33.2
WOVE — ICS	17.8	24	36.4	33.2
ICS $\equiv$ WOVE	43.9	49	67.5	63.2
ICS — HOUSE	22.2	24	36.4	33.2
HOUSE — ICS	42.9 ^{**}	24	36.4	33.2
ICS $\equiv$ HOUSE	69.7 ^{**}	49	67.5	63.2

(Fortsetzung der Tabelle auf der nächsten Seite)

(noch: Tabelle 60)

ICS — IMPR	21.7	24	36.4	33.2
IMPR — ICS	34.5	24	36.4	33.2
ICS $\equiv$ IMPR	56.5	49	67.5	63.2
ICS — SPI	16.1	24	36.4	33.2
SPI — ICS	38.0	24	36.4	33.2
ICS $\equiv$ SPI	59.0	49	67.5	63.2
ICS — CAPA	26.6	24	36.4	33.2
CAPA — ICS	18.1	24	36.4	33.2
ICS $\equiv$ CAPA	55.4	49	67.5	63.2
ICS — ACLA	27.1	24	36.4	33.2
ACLA — ICS	20.0	24	36.4	33.2
ICS $\equiv$ ACLA	62.4	49	67.5	63.2

Legende:

df Zahl der Freiheitsgrade;

* S_E -Statistik signifikant (Irrtumswahrscheinlichkeit .10);** S_E -Statistik signifikant (Irrtumswahrscheinlichkeit .05).

Zur Bedeutung der Variablen vgl. Tabelle 29.

Für $k > 0$ sind die Kreuzkorrelationen $r_{\hat{u}\hat{v}}(k)$ im Sinne einer Granger-kausalen Beeinflussung der ersten durch die zweite Reihe zu verstehen. Entsprechend beschreiben die $r_{\hat{u}\hat{v}}(k)$ für $k < 0$ die Beziehungen zwischen der zweiten Reihe und der verzögerten ersten Reihe, d.h. es wird der Granger-kausale Einfluß der ersten auf die zweite Reihe gemessen.

Tabelle 60 nennt die auf den Kreuzkorrelogrammen basierende

S_K -Statistik zusammen mit den kritischen Werten der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeiten .05 und .10.¹⁾ Der S_K -Test ist für drei Kausalmuster durchgeführt:²⁾

$Y \longrightarrow X$

$X \longrightarrow Y$

$Y \rightleftharpoons X$

5622 Interpretation der Kreuzkorrelogramme

1. ICS_t vs. CD_t/CA_t

Die S_K -Statistik läßt für die Beziehung zwischen dem ICS und CD_t bzw. CA_t die Existenz von Granger-Kausalität vermuten, denn für die Kausalmuster

$ICS \longrightarrow CD$

$ICS \longrightarrow CA$

liegen signifikante bzw. fast signifikante Werte vor (Irrtumswahrscheinlichkeit .10). Offensichtlich werden die relativ hohen Werte der S_K -Statistik durch einen einfachen Granger-kausalen Einfluß des ICS auf CD_t bzw. CA_t - oder, wie unten zu erörtern ist, durch gleichzeitige Granger-Kausalität - gestützt, denn die S_K -Statistik der Kausalmuster

$CD \longrightarrow ICS$

$CA \longrightarrow ICS$

ist auch für Irrtumswahrscheinlichkeit .10 nicht signifikant, während die Kausalmuster

1) Zum S_K -Test vgl. S. 179.

2) Zur Problematik der Anwendung des S_K -Tests auf Teilbereiche des Kreuzkorrelogramms vgl. S. 179.

$$\text{ICS} \longrightarrow \text{CD}$$

$$\text{ICS} \longrightarrow \text{CA}$$

signifikante S_K -Statistiken aufweisen (Irrtumswahrscheinlichkeiten .05 bzw. .10).

In den Kreuzkorrelogrammen (vgl. die Tabellen 50 und 51) fallen die relativ hohen Koeffizienten für den Lag-Bereich $0 \leq k \leq -3$ auf; die unverzögerte und die um jeweils ein, zwei und drei Quartale verzögerte transformierte ICS_t -Reihe ist mit der transformierten CD_t - bzw. CA_t -Reihe also positiv korreliert. Für $-3 \leq k \leq -24$ sind die $r_{\hat{u}\hat{v}}(k)$ ausnahmslos sehr niedrig und deuten nicht auf eine Granger-kausale Beziehung zwischen den Ausgabenreihen und der verzögerten ICS-Reihe hin. Das schwingungsähnliche Verhalten der $r_{\hat{u}\hat{v}}(k)$ in diesem Lag-Bereich könnte allerdings bei der Identifikation der Transferfunktion-Form von Bedeutung sein.

Für Lags $k > 0$ bestätigt das Erscheinungsbild der Kreuzkorrelationen die These, der ICS werde nicht einfach Granger-kausal von CD_t bzw. CA_t beeinflusst. Der vereinzelte größere Koeffizient für Lag $k = 5$ sollte jeweils auf Stichprobenvariation zurückzuführen sein.

2. ICS_t vs. YDQU_t

Die S_K -Statistik weist nur für das Kausalmuster

$$\text{YDQU} \longrightarrow \text{ICS}$$

einen relativ hohen, jedoch nicht signifikanten Wert auf. Der extrem niedrige Wert der S_K -Statistik des Kausalmusters

$$\text{ICS} \longrightarrow \text{YDQU}$$

erlaubt die Feststellung, daß der ICS im Sinne einfacher Granger-Kausalität keine nennenswerte Information zur Prognose von $YDQU_t$ besitzt.

Die $r_{\hat{u}\hat{v}}(k)$ (vgl. Tabelle 52) geben auch für $k > 0$ wenig Hinweise auf ausgeprägte Beziehungen. Sie scheinen zwar ein oszillierendes Element aufzuweisen, aber die Ausschläge sind zu gering, um die Erwartung auf die Signifikanz der Parameter bei der Schätzung der Transferfunktion-Form zu rechtfertigen.¹⁾

3. ICS_t vs. $UNRA_t$

Keines der in Tabelle 60 berücksichtigten Kausalmuster besitzt eine signifikante S_K -Statistik. Allerdings deuten die Kreuzkorrelationen in Tabelle 53 wegen des hohen Koeffizienten für Lag $k = 0$ auf die Existenz gleichzeitiger Granger-Kausalität zwischen dem ICS und $UNRA_t$ hin. Da sich für Lags $k = -1, -2$ noch mäßig große Koeffizienten finden, die zudem mit dem Koeffizienten für Lag $k = 0$ das negative Vorzeichen gemein haben, wäre auch eine Interpretation im Sinne eines einfachen Granger-kausalen Einflusses des ICS auf $UNRA_t$ möglich, der sich nur wegen der zu geringen Beobachtungshäufigkeit auch noch in der Korrelation für Lag $k = 0$ ausdrückt. Vielleicht würde bei Verwendung von Monatsdaten der für Lag $k = 0$ gemessene Koeffizient in den negativen Lag-Bereich überwechseln. Festzuhalten bleiben im besonderen die negativen Korrelationen für Lags $k = 0, -1, -2$, die eine kurzfristige gegengerichtete Beziehung zwischen dem

1) Die von Adams/Green (1965) und Shapiro (1972) berichtete positive Korrelation zwischen dem ICS und einem verzögerten Einkommensindex läßt sich damit nicht bestätigen. Wie in Abschnitt 22 ausgeführt, könnten die Ergebnisse dieser Untersuchungen auf die unzureichende Berücksichtigung der autokorrelativen Struktur der Reihen bzw. der stochastischen Größe zurückzuführen sein.

Konsumklima und den Arbeitslosenzahlen anzeigen.¹⁾

4. ICS_t vs. $WOWE_t$

Von den Kausalmustern in Tabelle 60 weist keines eine signifikante S-Statistik auf. Dennoch kann die Existenz einer der Formen von Granger-Kausalität aufgrund der in Tabelle 54 ausgewiesenen Kreuzkorrelationen vermutet werden, da für Lags $k = 0, -1$ hohe, jeweils positive Koeffizienten vorliegen. Formal betrachtet handelt es sich um das Kausalmuster

$$ICS \Rightarrow\Rightarrow WOWE$$

Allerdings könnte - entsprechend zu den Verhältnissen für ICS_t vs. $UNRA_t$ - die Vermutung gerechtfertigt sein, tatsächlich liege ein einfacher Granger-kausaler Einfluß des ICS auf $WOWE_t$ vor; in diesem Falle verhinderte die nur quartalsweise Erhebung der Daten das "Hinüberwandern" des für Lag $k = 0$ gemessenen Koeffizienten in den negativen Lag-Bereich.

Auffällig ist wiederum die Kurzfristigkeit der Beziehung: interpretationsfähige Werte existieren nur für Lags $k = 0, 1$. Der für Lag $k = 5$ gemessene hohe negative Koeffizient ist vermutlich eher durch Stichprobenvariation als durch wirklich existierende Beziehungen verursacht.²⁾

5. ICS_t vs. $HOUSE_t$

Die S_K -Statistik der Kausalmuster

- 1) Der Vergleich mit den Ergebnissen bei Mueller (1963), Adams/Green (1972) und Shapiro (1972) zeigt, daß die dort berichtete negative Korrelation zwischen dem ICS und einem um einige Lags verzögerten Arbeitslosenindex nicht zu bestätigen ist, wenn der autokorrelativen Struktur der Reihen Rechnung getragen wird.
- 2) Der von Adams/Green (1965) behauptete positive Zusammenhang zwischen dem ICS und verzögerten Werten eines Arbeitsstundenindex' läßt sich also nicht auffinden. Die in Abschnitt 22 geäußerte Kritik an der Behandlung des Problems der Autokorrelation der stochastischen Größe bei Adams/Green wird hierdurch bestätigt.

HOUSE $\longrightarrow$ ICSICS $\Longleftarrow$ HOUSE

ist jeweils signifikant für Irrtumswahrscheinlichkeit .05. Wie das Kreuzkorrelogramm (vgl. Tabelle 55) zeigt, liegen relativ hohe positive Koeffizienten für Lags $k = 0, 1$ und - etwas abgeschwächt - für Lag $k = -1$ vor. Die Annahme einer kurzfristigen Feedback-Beziehung liegt daher nahe, wenn auch die Möglichkeit der Fehlinterpretation aufgrund der Kovarianz der $r_{uv}(k)$ eingeräumt werden muß. Die hohen negativen Korrelationen für Lags $k = 9, 24, -3, -10$ sind vermutlich der Stichprobenvariation zuzurechnen.

6. ICS_t vs. $IMPR_t$

Mit 34.5 ist die S_K -Statistik des Kausalmusters

 $IMPR \longrightarrow ICS$

signifikant für Irrtumswahrscheinlichkeit .10. Tatsächlich bestätigt das Erscheinungsbild der Kreuzkorrelationen (vgl. Tabelle 56) hier die Annahme eines einfachen Granger-kausalen Einflusses von $IMPR_t$ auf den ICS, da für Lags $k = 1, 2, 4$ hohe Koeffizienten vorliegen, während der Koeffizient für Lag $k = 0$ niedrig genug ist, um die Möglichkeit der Simultaneität der transformierten Reihen - wie sie in den anderen Kreuzkorrelogrammen häufig zu beobachten ist - ausschließen zu können. Die negativen Vorzeichen der Koeffizienten für Lags $k = 1, 2, 4$ weisen auf eine gegenläufige Beziehung zwischen dem ICS und der $IMPR_t$ -Reihe hin. Die den ICS "treibende" stochastische Größe antwortet also mit positiven (negativen) Bewegungen auf negative (positive) Veränderungen der $IMPR_t$ "treibenden" stochastischen Größe. Die Antwort der stochastischen Größe des ICS ist dabei am stärksten in dem auf die Veränderung der stochastischen Größe von $IMPR_t$ unmittelbar folgenden Quartal; weitere nennenswerte Ausschläge zeigen sich im zweiten und vierten Quartal.

7. ICS_t vs. SPI_t
Für das Kausalmuster

$SPI \longrightarrow ICS$

errechnet sich eine signifikante S_K -Statistik (Irrtumswahrscheinlichkeit .05). Ob SPI_t tatsächlich einen einfachen Granger-kausalen Einfluß auf den ICS ausübt, muß angesichts des Erscheinungsbildes der Kreuzkorrelationen in Tabelle 57 fraglich erscheinen: zwar ist der Koeffizient für Lag $k = 1$ mit .23 relativ hoch, aber der für Lag $k = 0$ gemessene Koeffizient besitzt den gleichen Wert und weist damit auf die Möglichkeit simultaner Beziehungen - gleichzeitiger Granger-Kausalität - hin. Da sich auch für Lag $k = -3$ ein relativ hoher Koeffizient findet, ist sogar die Möglichkeit einer Feedback-Beziehung nicht ganz auszuschließen. Festzuhalten bleibt das positive Vorzeichen der Koeffizienten im Lag-Bereich $-3 \leq k \leq 3$, das ein kurzfristiges gleichgerichtetes Verhalten des Konsumklimas und der Aktienkurse anzeigt.

8. ICS_t vs. $CAPA_t$

Die S_K -Statistik ist zwar für keines der in Tabelle 60 ausgewiesenen Kausalmuster signifikant: wie das Kreuzkorrelogramm (vgl. Tabelle 58) jedoch ausweist, liegt für den Lag-Bereich $0 \leq k \leq -4$ eine auf hohem positivem Niveau beginnende Reihe von Kreuzkorrelationen vor, die den Eindruck eines kurzfristig wirksamen Granger-kausalen Einflusses des ICS auf $CAPA_t$ vermitteln. Es muß jedoch betont werden, daß der mit .33 für Lag $k = 0$ höchste Koeffizient des Kreuzkorrelogramms auch die Möglichkeit simultaner Beziehungen offen hält. Für einen Einfluß von $CAPA_t$ auf den ICS finden sich im Lag-Bereich $1 \leq k \leq 24$ keine überzeugenden Hinweise.¹⁾

1) Anderslautende Ergebnisse von Adams/Green (1965) müssen auf die unzureichende Behandlung der Autokorrelation der stochastischen Größe zurückgeführt werden.

9. ICS_t vs. $ACLA_t$

Auffallend ist die S_K -Statistik des Kausalmusters

$$ICS \rightleftharpoons ACLA$$

die mit 62.4 signifikant ist (Irrtumswahrscheinlichkeit .05).

Da die S_K -Statistik für

$$ICS \longrightarrow ACLA$$

$$ACLA \longrightarrow ICS$$

jeweils recht niedrig ist, läßt sich die Existenz einer hohen Kreuzkorrelation für Lag $k = 0$ vermuten. Dieser Eindruck wird aufgrund des Kreuzkorrelogramms in Tabelle 58 bestätigt, denn der Koeffizient für Lag $k = 0$ ist mit .41 signifikant. Da die Kreuzkorrelationen für Lags $k \geq 1$ und $k \leq -1$ kein einheitliches Bild vermitteln und mit wenigen Ausnahmen sehr niedrig sind, könnte hier tatsächlich das Kausalmuster

$$ICS \rightleftharpoons ACLA$$

vorliegen, d.h. den ICS und $ACLA_t$ verbindet (reine) gleichzeitige Granger-Kausalität.

5623 Zusammenfassung der Ergebnisse der Kreuzkorrelogramm-Analyse

1. Die in Tabelle 60 ausgewiesenen S_K -Statistiken ebenso wie die Kreuzkorrelogramme in den Tabellen 50 bis 59 vermitteln den Eindruck von nur schwach ausgeprägten Beziehungen zwischen dem ICS und den berücksichtigten ökonomischen Variablen.

2. Wenn sich in den S_K -Statistiken bzw. den Kreuzkorrelogram-

men nennenswerte Beziehungen widerspiegeln, sind sie regelmäßig durch die Existenz gleichzeitiger Granger-Kausalität, d.h. Simultaneität zwischen den Reihen, bestimmt. Es muß offen bleiben, ob dieser Sachverhalt durch eine veränderte Ermittlungshäufigkeit der Daten auszuräumen wäre.

Nur für die Beziehung zwischen dem ICS und $IMPR_t$ ergeben sich klare Hinweise auf eine Beziehung im Sinne einfacher Granger-Kausalität, da hier nur für Lag $k > 0$ größere Koeffizienten auftreten.

3. Wenn Beziehungen vorliegen, sind sie kurzfristiger Natur. Stets finden sich nennenswerte Kreuzkorrelationen nur für Lags - 4 $\leq k \leq 4$, wobei von vereinzelten "Ausreißern", die auf Stichprobenvariation zurückzuführen sein dürften, abgesehen wird.

4. Die Vorzeichen der Kreuzkorrelationen entsprechen den Erwartungen aufgrund der Lehren der "Psychological Economics". Danach ist ein positiver Zusammenhang zwischen dem Konsumklima und gesamtwirtschaftlichen Größen wie diskretionären Konsumausgaben, der Bautätigkeit, der Kapazitätsauslastung und dem Beschäftigungsgrad - Größen also, deren Ansteigen im allgemeinen eine verbesserte konjunkturelle Lage anzeigt - gegeben. Ferner kann der in den Kreuzkorrelationen aufgedeckte negative Zusammenhang zwischen dem ICS und $UNRA_t$ bzw. $IMPR_t$ als Reflex der gegengerichteten Beziehung zwischen dem Konsumklima und Arbeitslosenzahlen bzw. Preissteigerungsraten betrachtet werden.

Es muß der Spekulation überlassen bleiben, die positiven Beziehungen zwischen dem Konsumklima und der wöchentlichen Arbeitsstundenzahl ($WOWE_t$) bzw. den Aktienkursen (SPI_t) zu begründen.

563 Identifikation und Schätzung der Transferfunktion-Form5631 Allgemeines

1. Die Kreuzkorrelogramm-Analyse in Abschnitt 562 hat für einige der berücksichtigten Reihen Beziehungen zum ICS im Sinne von Granger-Kausalität aufgedeckt.

Im folgenden ist die Transferfunktion-Form jedoch nur für die Beziehungen ICS_t vs. CD_t/CA_t und ICS_t vs. $IMPR_t$ identifiziert und geschätzt. Im ersten Fall ist aufgrund des Erscheinungsbildes des Kreuzkorrelogramms ein einfacher Granger-kausaler Einfluß des ICS auf CD_t bzw. CA_t unterstellt, im zweiten Fall ein einfacher Granger-kausaler Einfluß von $IMPR_t$ auf den ICS. Es sind damit solche Reihen außer Betracht gelassen, die mit dem ICS durch gleichzeitige Granger-Kausalität verbunden sind. Da allein aufgrund der Daten nicht entschieden werden kann, ob hier jeweils echte Simultaneität vorliegt oder eine durch unzureichende Beobachtungshäufigkeit verdeckte Beziehung im Sinne einfacher Granger-Kausalität (oder Granger-Feedback), ist von der Identifikation und Schätzung der Transferfunktion-Form, die in der in Gleichung (5.10) vorgestellten Form die Existenz einfacher Granger-Kausalität unterstellt, abgesehen. Zwar weist auch das Kreuzkorrelogramm der jeweils transformierten Reihen des ICS und CD_t bzw. CA_t für Lag $k = 0$ einen beachtlichen Wert auf; hier erscheint jedoch, gestützt durch die Lehren der "Psychological Economics", die Annahme einfacher Granger-Kausalität eher zu rechtfertigen zu sein.

2. Der ICS ist aufgrund des Erscheinungsbildes des jeweiligen Kreuzkorrelogramms im Verhältnis zu CD_t bzw. CA_t als unab-

hängige Variable. im Verhältnis zu IMPR_t als abhängige Variable zu betrachten. Diese Doppelfunktion erfordert eine Anpassung der in Abschnitt 53 verwendeten Notation. In den Gleichungen (5.10) bzw. (5.25) ist Y_t bzw. (die transformierte Reihe) U_t als abhängige Variable aufgeführt. Entsprechend ist dort X_t bzw. V_t die unabhängige Variable.

Im Rahmen der Kreuzkorrelogramm-Analyse in Abschnitt 562 ist die transformierte ICS-Reihe durchgehend als Realisation von weißem Rauschen U_t bezeichnet, während die jeweils zweite Reihe als Realisation von weißem Rauschen V_t aufgeführt ist.

Der ICS ist im Verhältnis zu CD_t bzw. CA_t eine unabhängige Variable - die Übernahme der Notation der Gleichungen (5.10) und (5.25) würde zu Widersprüchen führen, da dort die unabhängige Variable mit X_t (V_t) bezeichnet ist, während die transformierte ICS-Reihe gemäß der in Abschnitt 562 verwendeten Terminologie eine Realisation von U_t ist.

Um diese Widersprüche aufzulösen, wird für die Beziehung zwischen dem ICS und CD_t bzw. CA_t eine Notation verwendet, die jene der Gleichungen (5.10) und (5.25) umkehrt: die Transferfunktion-Formen sind nun so zu definieren, daß X_t (V_t) abhängige Variable und Y_t (U_t) unabhängige Variable ist. Es sind also jeweils X und Y (V und U) zu vertauschen.

Im Verhältnis zwischen IMPR_t und dem ICS ist eine Veränderung der Notation nicht erforderlich, da hier der ICS die abhängige Variable ist. Die Notation der Gleichungen (5.10) und (5.25) sowie die in dem Kreuzkorrelogramm in Tabelle 37 ist hier widerspruchsfrei und kann unverändert übernommen werden.

5632 Identifikation56321 Der ICS als unabhängige Variable

Die folgenden Ausführungen beziehen sich wegen der Ähnlichkeit der Kreuzkorrelogramme der transformierten Reihen sowie der zur Transformation verwendeten univariaten ARIMA-Modelle auf die Beziehung des ICS zu CD_t und CA_t .

1. Bei der Identifikation der Transferfunktion-Form der transformierten Reihen ist die einfachste Entscheidung in bezug auf die Ordnung (r,s,b) der Transferfunktion für den Parameter b , der den Verzug in der Reaktion der transformierten Ausgabereihen auf den transformierten ICS beschreibt, zu treffen: da eine relativ hohe Kreuzkorrelation bereits für Lag $k = 0$ besteht, ist auch $b = 0$.

Für die Bestimmung von r und s liegen solche klaren Hinweise nicht vor. Wenn aufgrund des Erscheinungsbildes der $r_{\hat{u}}(k)$ angenommen wird, die Koeffizienten $v_{V_k}^{1)}$ folgten für Lags $0 \geq k \geq -2$ keinem bestimmten Muster, während sie für Lags $k < -2$ einer Differenzengleichung erster Ordnung der Form

$$(5.43) \quad (1 - b_{V1}B)v_{V_k} = 0$$

gehorchten, so gilt:

$$(5.44) \quad \begin{aligned} (s - r + 1) &= 3 \\ r &= 1 \end{aligned}$$

Die Ordnung der Transferfunktion lautete dann also $(1,3,0)$.

Alternativ könnte eine Transferfunktion der Ordnung $(2,3,0)$

1) Zur Definition der v_{V_k} vgl. Abschnitt 533.

vorliegen, für die die v_{V_k} für Lags $k = 0, -1$ keinem bestimmten Muster folgen und für Lags $k \leq -2$ der Differenzengleichung zweiter Ordnung

$$(5.45) \quad (1 - b_{V1}B - b_{V2}B^2)v_{V_k} = 0$$

gehören. Das Erscheinungsbild der $r_{\hat{u}\hat{v}}(k)$ für Lags $k \leq -2$ in den Tabellen 50 und 51 würde am ehesten durch konjugiert komplexe Wurzeln der polynomischen Gleichung (5.27) oder durch reale Wurzeln unterschiedlichen Vorzeichens beschrieben.

Falls das oszillierende Verhalten der Kreuzkorrelationen für Lags $k < -3$ ausschließlich der Stichprobenvariation zugeschrieben wird, d.h. wenn angenommen wird, $r_{UV}(k) = 0$ für $k < -3$, so läge eine Transferfunktion der Ordnung $(0,3,0)$ vor, da

$$(5.46) \quad \begin{aligned} (s - r + 1) &= 4 \\ r &= 0 \end{aligned}$$

Der weiteren Untersuchung ist das letztgenannte Modell zugrundegelegt, das die Anforderungen des "principle of parsimony" am besten erfüllt und doch das Wesentliche der Beziehung erfaßt. Die Verwendung der aufwendiger parametrisierten Modelle dürfte sich erst bei Vorliegen eines größeren Samples empfehlen.

2. Die Identifikation des Noise-Modells der Transferfunktion-Form der transformierten Reihen bedient sich - Box/Jenkins folgend - des Autokorrelogramms von $\hat{l}_t$, wobei $\hat{l}_t$ die Schätzung von L_t ist.¹⁾ $\hat{l}_t$ errechnet sich hier wie folgt:

1) L_t ist gemäß Gleichung (5.29) definiert, wobei die Indizes U durch die Indizes V zu ersetzen sind.

$$(5.47) \quad \hat{l}_t = \hat{v}_t - (.64 + .69B + .51B^2 + .67B^3)\hat{u}_t$$

(für Gebrauchsgüterausgaben)

$$(5.48) \quad \hat{l}_t = \hat{v}_t - (.61 + .51B - .41B^2 + .64B^3)\hat{u}_t$$

(für Autoausgaben)

Die Schätzungen der v_{VK} basieren auf der in Gleichung (5.26) dargestellten Beziehung, wobei für die $r_{UV}(k)$ die $r_{\hat{u}\hat{v}}(k)$ und für σ_U und σ_V die Standardfehler von $\hat{u}_t$ und $\hat{v}_t$ eingesetzt sind. Bei der Gegenüberstellung der Gleichungen (5.29) und (5.47) bzw. (5.48) ist zu bedenken, daß hier $b = 0$ und $B_V(B) = 1$.

Tabelle 61 weist das Autokorrelogramm von $\hat{l}_t$ für Gebrauchsgüter- und Autoausgaben aus. Für Gebrauchsgüterausgaben ist $\hat{l}_t$ kaum von einer Realisation von weißem Rauschen zu unterscheiden, während für Autoausgaben ein Moving Average-Modell erster Ordnung wegen des abrupten Abfallens der Autokorrelationen für Lag $k = 2$ angebracht sein könnte. Aufgrund der Ausführungen von Granger/Newbold (vgl. Abschnitt 533) müßte L_t (für beide Ausgabekategorien) durch ein Moving Average-Modell dritter Ordnung zu beschreiben sein, denn die Ordnung von $C_V(B)$ muß gleich der größeren der Ordnungen von $A_V(B)B^b$ und $B_V(B)$ sein, wenn diese unterschiedlich sind. Die Abweichungen der Zeitreihennatur von $\hat{l}_t$ von der nach Granger/Newbold zu erwartenden mögen teilweise auf der Identifikations-Strategie beruhen, die generell nur grobe Anhaltspunkte für die Ordnungen der jeweiligen Operatorpolynome verschaffen kann. Darüberhinaus fügt die begrenzte Zahl der Beobachtungen dem Rückschluß auf die Eigenschaften der zugrundeliegenden Prozesse gewisse Unsicherheiten zu.

Als ein Kompromiß zwischen dem theoretisch zu erwartenden und faktisch vorgefundenen Modell ist für L_t jeweils ein Moving Average-Modell erster Ordnung identifiziert, d.h.

$$(5.49) \quad L_t = (1 - c_{V1}B)E_{Vt}$$

Dieses Modell ist zweifellos für Autoausgaben eher als für Gebrauchsgüterausgaben zu akzeptieren.

3. Nach der Identifikation des Noise-Modells der Transferfunktion-Form der transformierten Prozesse ist die umfassende Formulierung der Transferfunktion-Form der nicht transformierten Prozesse (vgl. Gleichung (5.10)) möglich. Unter Einbeziehung der zur Transformation zu weißem Rauschen verwendeten univariaten ARIMA-Modelle ergibt sich als Transferfunktion-Form der nicht transformierten Prozesse:

$$(5.50) \quad (1 - B)CD_t(CA_t) = (a_{V0} + a_{V1}B + (a_{V2} + a_{V0}b_{Y2})B^2 + (a_{V3} + a_{V1}b_{Y2})B^3 + a_{V2}b_{Y2}B^4 + a_{V3}b_{Y2}B^5)(1 - B)ICS_t + (1 - c_{V1}B + b_{Y2}B^2 - c_{V1}b_{Y2}B^3)E_{Xt}$$

Die Parameter a_{V_k} und c_{V_k} sind gemäß Gleichung (5.25), der Parameter b_{Y_k} ist gemäß Gleichung (5.23) definiert.

56322 Der ICS als abhängige Variable

1. Wiederum ist bei der Identifikation der Transferfunktion-Form der transformierten Reihen die einfachste Entscheidung in bezug auf die Ordnung (r,s,b) der Transferfunktion für den Parameter b zu treffen. Da $r_{\hat{u}\hat{v}}(0)$ sehr niedrig ist, wäh-

rend für Lag $k = 1$ ein relativ hoher Koeffizient vorliegt, kann der die Totzeit beschreibende Parameter mit $b = 1$ angesetzt werden.¹⁾

Über die Ordnungen r und s der Operatorpolynome $B_V(B)$ und $A_V(B)$ können keine ähnlich bestimmten Aussagen getroffen werden. Recht plausibel wäre die Annahme, die $r_{\hat{u}\hat{v}}(k)$ folgten für Lags $1 \leq k \leq 24$ einer gedämpft sinusförmigen Schwingung, der eine Differenzengleichung zweiter Ordnung mit konjugiert komplexen Wurzeln zugrundeläge. Die Zahl der Perioden, für die die $r_{UV}(k)$ ohne bestimmtes Muster sind, ist dann mit null angesetzt. Nach diesen Überlegungen wäre die Ordnung (r,s,b) der Transferfunktion mit $(2,1,1)$ gegeben, denn es gilt:

$$(5.51) \quad \begin{aligned} (s - r + 1) &= 0 \\ r &= 2 \end{aligned}$$

Wird das sinusförmige Verhalten der $r_{\hat{u}\hat{v}}(k)$ nicht berücksichtigt, sondern angenommen $r_{UV}(k) = 0$ für $k \neq 1$, so folgt:

$$(5.52) \quad \begin{aligned} (s - r + 1) &= 1 \\ r &= 0 \end{aligned}$$

Die Ordnung (r,s,b) der Transferfunktion wäre dann $(0,0,1)$. Die an sich nennenswerte Kreuzkorrelation für Lag $k = 2$ ist hier ausschließlich der Stichprobenvariation zugeschrieben.

Auch hier ist es empfehlenswert, dem "principle of parsimony" Rechnung zu tragen und das letztgenannte, sparsamer parametrisierte Modell zur Grundlage der weiteren Phasen der Identifikations- und Schätzungsstrategie zu machen.

2. Die Identifikation des Noise-Modells folgt wieder dem von Box/Jenkins empfohlenen Verfahren (vgl. Abschnitt 533), d.h. es wird das Autokorrelogramm von $\hat{l}_t$ - der Schätzung von L_t - untersucht.

1) Zur Definition von b vgl. S. 182.

Da für die identifizierte Transferfunktion angenommen ist, daß $b = 1$ und $B_U(B) = 1$, folgt:

$$(5.53) \quad \hat{l}_t = \hat{u}_t - 4.72B\hat{v}_t$$

Diese Beziehung ist wieder mithilfe der Kreuzkorrelationen $r_{\hat{u}\hat{v}}(k)$ und der Standardfehler von $\hat{u}_t$ und $\hat{v}_t$ nach Maßgabe der Gleichungen (5.26) und (5.29) berechnet.

Wie Tabelle 62 zeigt, könnte $\hat{l}_t$ als Realisation von weißem Rauschen angesehen werden, da über den gesamten ausgewiesenen Lag-Bereich keine nennenswerten Autokorrelationen auftreten.

Dies widerspräche den Erwartungen, denn nach Granger/Newbold muß die Ordnung von $C_U(B)$ gleich der größeren der Ordnungen von $A_U(B)B^b$ und $B_U(B)$ sein, wenn diese Ordnungen unterschiedlich sind. Hier ist $B_U(B) = 1$, sodaß die Ordnung von $C_U(B)$ gleich der von $A_U(B)B^b$ sein sollte, d.h.

$$(5.54) \quad C_U(B) = (1 - c_{U1}B)$$

Wie bereits ausgeführt, sollten die Unterschiede zwischen der theoretisch zu erwartenden und der aufgrund des Autokorrelogramms von $\hat{l}_t$ identifizierten Ordnung von $C_U(B)$ nicht zu grose Bedenken auslösen. Das hier verwendete Instrumentarium kann nur dazu dienen, grobe Hinweise auf die Ordnungen der Operatorpolynome zu ermitteln; Unschärfen sind hierbei - auch wegen der beschränkten Zahl der Beobachtungen - nicht zu vermeiden.

Es wird im folgenden unterstellt, das Noise-Modell der Transferfunktion-Form der zu weißem Rauschen transformierten Prozes-

Tabelle 62

Autokorrelationen ($\hat{r}_{11}(k)$) des Noise-Modells der Transferfunktion-Form der Transformation des ICS

Sample-Periode: 1954.1 - 1976.3

k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$\hat{r}_{11}(k)$	-.08	.05	-.13	-.13	-.13	.02	-.01	-.06	.13	-.14	-.04	.05	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$\hat{r}_{11}(k)$	.08	.07	-.10	.17	-.18	.12	-.08	-.02	.04	.01	-.18	-.02	.12

se laute:

$$(5.55) \quad L_t = (1 - c_U B) E_{U_t}$$

Dieses Modell nimmt also eher bezug auf die theoretisch zu erwartenden als die faktisch vorgefundenen Beziehungen.

3. Nach Integration der identifizierten Transferfunktion-Form der zu weißem Rauschen transformierten Reihen mit den Operatoren der zur Transformation verwendeten univariaten ARIMA-Modelle ergibt sich als Transferfunktion-Form der nicht transformierten Prozesse:

$$(5.56) \quad (1 - B)ICS_t = (a_{U0}B + a_{U0}a_{X1}B^2 + a_{U0}(a_{X2} + b_{Y2})B^3 + a_{U0}a_{X1}b_{Y2}B^4 + a_{U0}a_{X2}b_{Y2}B^5)(1 - B)^2IMPR_t + (1 + c_{U1}B + b_{Y2}B^2 + c_{U1}b_{Y2}B^3)E_{Y_t}$$

5633 Schätzung der Transferfunktion-Form und Diagnostic Checks

Es ist auffallend, daß trotz des Bemühens, dem "principle of parsimony" Rechnung zu tragen, jede der identifizierten Transferfunktion-Formen (vgl. die Gleichungen (5.50) und (5.56)) eine hohe Anzahl von Parametern aufweist. Hierfür ist offensichtlich die sequentielle Identifikations-Strategie - die Operatorpolynome sind nacheinander und nicht simultan identifiziert - verantwortlich.¹⁾

Die Schätzung dieser aufwendig parametrisierten Modelle aufgrund von Samples des hier verfügbaren Umfangs erscheint we-

1) S. auch Granger/Newbold (1977), S. 240: "Now, the great difficulty with such a procedure, ... ist that, unless the single series models contain very few parameters, it is likely to yield a model with a great abundance of parameters."

gen der zu vermutenden Instabilität der Ergebnisse nicht ratsam. Es sind stattdessen im folgenden einfacher parametrisierte Modelle geschätzt, die die wesentlichen Eigenschaften der ursprünglich identifizierten Modelle bewahren.¹⁾ Regelmäßig sind dabei nur solche Parameter berücksichtigt, für die sich signifikante Schätzungen ergeben.

Die Adäquanz der geschätzten Modelle ist anschließend mithilfe der in Abschnitt 535 genannten Diagnostic Checks überprüft.

56331 Der ICS als unabhängige Variable

1. Die Ergebnisse der Schätzung der Transferfunktion-Form für die Beziehung des ICS zu CD_t bzw. CA_t sind in Tabelle 63 ausgewiesen. Die Ergebnisse erlauben die folgenden Feststellungen:

- Für Gebrauchsgüter- wie für Autoausgaben entspricht die geschätzte Transferfunktion im wesentlichen der in Gleichung (5.50) vorgestellten, wenn sich auch für Lags $k = 2, 4, 5$ keine signifikanten Parameterschätzungen ergeben. Zumindestens die Signifikanz des Parameters für Lag $k = 2$ dürfte sich bei Vorliegen eines neuen Samples einstellen, denn es ließe sich kein anderer plausibler Grund für die Nichtsignifikanz dieses Parameters - bei gleichzeitiger Signifikanz des Parameters für Lag $k = 3$ - finden.
- Die Noise-Modelle sind für beide Ausgabekategorien sparsamer parametrisiert als in Gleichung (5.50):
für Autoausgaben wird ein Moving Average-Modell ers-

1) Dieses Verfahren wird auch von Granger/Newbold befürwortet. Vgl. Granger/Newbold (1977). S. 240.

Tabelle 63

Ergebnisse der Schätzung der Transferfunktion-Form für
Gebrauchsgüterausgaben bzw. Autoausgaben

(In Klammern: t-Statistik)

Sample-Periode: 1954.1 - 1976.3

$$1. (1 - B)CD_t = (.86 + .80B + .66B^3)(1 - B)ICS_t + 2.25 + E_{Xt}$$

(3.25) (2.94) (2.71) (2.39)

$$\bar{R}^2 = .25 \quad F_{(4,85)} = 10.6$$

$$2. (1 - B)CA_t = (.72 + .61B + .58B^3)(1 - B)ICS_t +$$

(3.09) (2.48) (2.59)

$$+ (1 - .33B)E_{Xt}$$

(3.12)

$$\bar{R}^2 = .27 \quad F_{(4,85)} = 11.7$$

Legende:

CD_t , CA_t s. Tabelle 29.

ter Ordnung unterstellt, für Gebrauchsgüter sogar weißes Rauschen. Als Gründe hierfür können genannt werden:

- die Verwendung erster Differenzen beseitigt im Regelfall einen hohen Anteil der Autokorrelation aus ökonomischen Reihen bzw. den stochastischen Größen ökonomischer Modelle;
- die niedrige Zahl der Beobachtungen erschwert das Aufdecken komplizierter Strukturen.
- Es bestätigt sich der aufgrund der Kreuzkorrelogramm-Analyse gewonnene Eindruck, wonach die Beziehung des ICS zu diskretionären Konsumausgaben kurzfristiger Natur ist; sie besteht im wesentlichen nur

im Rahmen der ersten drei Quartale.

- Ebenfalls bestätigt wird die positive Beziehung des ICS zu diskretionären Konsumausgaben: einem Ansteigen (Absinken) des Konsumklimas folgt ein über mehrere Lags verteiltes Ansteigen (Absinken) diskretionärer Konsumausgaben.
- Die Lag-Verteilung des ICS ist - wenn man die Nichtsignifikanz des Parameters für Lag $k = 2$ einmal außer acht läßt - durch ein (langsames) Absinken der Parameter gekennzeichnet; dem entspricht die durchaus plausible Annahme, das Konsumklima beeinflusse diskretionäre Konsumausgaben mit im Zeitablauf abnehmender Stärke.

2. Die Tabellen 64 und 65, die die Autokorrelationen $r_{\hat{e}_X \hat{e}_X}(k)$ und die Kreuzkorrelationen $r_{\hat{e}_X \hat{e}_Y}(k)$ zeigen, stellen die Grundlage der Diagnostic Checks dar.¹⁾ Tabelle 66 führt die in Abschnitt 535 eingeführten Statistiken Q' , S' und S'' auf, zusammen mit den für die Zahl der Freiheitsgrade berichtigten kritischen Werten der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeiten .05 und .10.

Das Erscheinungsbild der $r_{\hat{e}_X \hat{e}_X}(k)$ bzw. $r_{\hat{e}_X \hat{e}_Y}(k)$ weist nicht auf nennenswerte Koeffizienten hin. Auch die Statistiken Q' , S' und S'' liegen jeweils unterhalb der kritischen Werte der Chi-Quadrat-Verteilung, Irrtumswahrscheinlichkeit .10. Die Adäquanz der identifizierten und geschätzten Transferfunktion-Formen kann somit als bestätigt gelten.

1) Vgl. hierzu Abschnitt 535.

Tabelle 64

Autokorrelationen ($r_{\hat{e}_X \hat{e}_X}(k)$) und Kreuzkorrelationen ($r_{\hat{e}_X \hat{e}_Y}(k)$) der Transferfunktion-

Form für CD

Sample-Periode: 1954.1 - 1976.3

	k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{e}_X \hat{e}_X}(k)$	k	.00	.05	.04	-.09	.04	.02	-.07	.04	-.12	.14	.00	.04	.11
	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{e}_X \hat{e}_X}(k)$	k	.04	.03	-.03	-.02	.14	-.10	.14	.04	.07	-.03	.02	-.08	.11
	0	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{e}_X \hat{e}_Y}(k)$	k	.04	.13	-.02	-.06	-.08	-.13	.04	.08	-.08	-.10	-.09	.00	.15
	13	14	15	16	17	18	19	20	21	22	23	24		
$r_{\hat{e}_X \hat{e}_Y}(k)$	k	.05	-.15	-.18	.16	-.03	-.05	.12	.06	-.12	-.12	-.01	.02	.11
	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12		
$r_{\hat{e}_X \hat{e}_Y}(k)$	k	-.02	-.05	.00	.10	.01	-.06	.11	-.10	.08	-.04	-.12	.00	.11
	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24		
$r_{\hat{e}_X \hat{e}_Y}(k)$	k	.12	.00	.14	-.13	.10	-.08	-.02	-.07	.07	.11	-.01	.00	.11

Tabelle 65

Autokorrelationen ($r_{\hat{e}_X \hat{e}_X}(k)$) und Kreuzkorrelationen ($r_{\hat{e}_X \hat{e}_Y}(k)$) der Transferfunktion-Form für CA_t

Sample-Periode: 1954.1 - 1976.3

k													Standard- fehler
	1	2	3	4	5	6	7	8	9	10	11	12	
$r_{\hat{e}_X \hat{e}_X}(k)$	.00	.03	-.06	-.18	-.01	.13	-.03	-.04	-.10	.03	-.01	.12	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{e}_X \hat{e}_X}(k)$	.07	-.01	-.05	.05	-.11	.15	.01	.16	-.06	.00	.10	.07	.11
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{e}_X \hat{e}_Y}(k)$	.06	.11	-.05	-.06	-.07	-.06	.11	.11	-.11	-.10	-.05	.02	.16
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{e}_X \hat{e}_Y}(k)$	-.02	-.19	-.17	.01	-.02	.02	.19	.07	-.15	-.12	.01	.01	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{e}_X \hat{e}_Y}(k)$	-.01	-.09	-.07	.06	-.02	-.03	-.09	-.11	.04	-.02	-.09	.03	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{e}_X \hat{e}_Y}(k)$	.15	.03	.16	-.14	.04	-.09	.00	-.09	.10	-.08	-.01	.00	.11
k	0	1	2	3	4	5	6	7	8	9	10	11	

Tabelle 66

Diagnostic Checks der identifizierten und geschätzten
Transferfunktion-Formen für Gebrauchsgüterausgaben (CD_t)
und Autoausgaben (CA_t)

	Q'	df	$\chi^2_{.05}$	$\chi^2_{.10}$
1. CD_t	10.6	24	36.4	33.2
2. CA_t	14.6	23	35.2	32.0
S'				
1. CD_t	21.4	21	32.7	29.6
2. CA_t	25.6	21	32.7	29.6
S''				
1. CD_t	15.7	24	36.4	33.2
2. CA_t	16.2	24	36.4	33.2

Legende:

df Zahl der Freiheitsgrade:

Q' , S' , vgl. Abschnitt 535.

S''

56332 Der ICS als abhängige Variable

1. Die für die Beziehung zwischen dem ICS und $IMPR_t$ geschätzte Transferfunktion-Form ist in Tabelle 67 ausgewiesen. Es läßt sich feststellen:

Tabelle 67

Ergebnisse der Schätzung der Transferfunktion-Form für
den ICS

(In Klammern: t-Statistik)

Sample-Periode: 1954.1 - 1976.3

$$(1 - B)ICS_t = (-3.57B - 2.74B^3)(1 - B)^2IMPR_t + \\ (3.15) \quad (2.31) \\ (1 + .21B^2)E_{Yt} \\ (2.09)$$

$$\bar{R}^2 = .20 \quad F_{(2,86)} = 10.9$$

Legende:

$IMPR_t$ s. Tabelle 29.

- Die geschätzte Transferfunktion-Form bewahrt im wesentlichen die Eigenschaften der identifizierten, in Gleichung (5.56) ausgewiesenen - mit dem Unterschied, daß sich hier die Schätzungen der Parameter für Lags $k = 2, 4, 5$ als nicht signifikant erweisen. Wie schon oben bei der geschätzten Transferfunktion für Gebrauchsgüter- bzw. Autoausgaben (vgl. Tabelle 63) ist zu erwarten, daß sich für Lag $k = 2$ bei Vorliegen eines neuen Samples eine signifikante Schätzung einstellt; jedenfalls gibt es keine plausiblen Gründe für die Nichtsignifikanz dieses Parameters bei gleichzeitiger Signifikanz der Schätzung für Lag $k = 3$.
- Das geschätzte Noise-Modell ist ein Moving Average-Modell zweiter Ordnung, dessen erster Parameter null

ist; die in der Gegenüberstellung mit dem identifizierten Noise-Modell in Gleichung (5.56) hervortretende sparsamere Parametrisierung mag auf die Verwendung erster bzw. zweiter Differenzen sowie die relativ geringe Zahl der Beobachtungen zurückzuführen sein. Auch hier sollte ein neues Sample zu einer signifikanten Schätzung des ersten Parameters führen.

- Wie schon für die Transferfunktion für Gebrauchsgüter- bzw. Autoausgaben läßt sich die Kurzfristigkeit der Beziehungen feststellen: der Einfluß der Preissteigerungen auf das Konsumklima konzentriert sich auf die ersten drei Quartale.
- Die Vorzeichen der Parameter der Transferfunktion bestätigen die schon anläßlich der Kreuzkorrelogramm-Analyse getroffene Feststellung, wonach eine gegengerichtete Beziehung zwischen dem Konsumklima und Preissteigerungen vorliegt.
- Die geschätzten Parameter sinken mit ansteigenden Lags ab; dies mag als Hinweis auf eine im Zeitablauf abnehmende Stärke des Einflusses der Preissteigerungen auf das Konsumklima verstanden werden.

2. Tabelle 68 weist die für die Diagnostic Checks wichtigen Autokorrelationen $r_{\hat{e}_Y \hat{e}_Y}(k)$ und Kreuzkorrelationen $r_{\hat{e}_Y \hat{e}_X}(k)$ aus. In Tabelle 69 sind die Statistiken Q' , S' und S'' aufgeführt, wieder mit den für die Zahl der Freiheitsgrade berechtigten kritischen Werten der Chi-Quadrat-Verteilung für Irrtumswahrscheinlichkeiten .05 und .10.

Tabelle 68

Autokorrelationen ($r_{\hat{e}_Y \hat{e}_Y}(k)$) und Kreuzkorrelationen ($r_{\hat{e}_Y \hat{e}_X}(k)$) der Transferfunktion-

Form des ICS

Sample-Periode: 1954.1 - 1976.3

k	1	2	3	4	5	6	7	8	9	10	11	12	Standard- fehler
$r_{\hat{e}_Y \hat{e}_Y}(k)$	-0.01	-0.02	-0.12	-0.09	-0.06	.04	-0.03	-0.15	-0.11	-0.15	.07	.05	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{e}_Y \hat{e}_Y}(k)$	.18	.01	.01	.07	-0.02	.00	.01	-0.08	.13	-0.03	-0.18	-0.06	.11
k	0	1	2	3	4	5	6	7	8	9	10	11	12
$r_{\hat{e}_Y \hat{e}_X}(k)$	.00	.13	-0.10	.10	-0.06	-0.27	-0.10	-0.10	.10	-0.11	.11	.06	.11
k	13	14	15	16	17	18	19	20	21	22	23	24	
$r_{\hat{e}_Y \hat{e}_X}(k)$	.00	.11	-0.04	.00	-0.07	.01	-0.04	.03	-0.05	.02	.02	.04	.11
k	-1	-2	-3	-4	-5	-6	-7	-8	-9	-10	-11	-12	
$r_{\hat{e}_Y \hat{e}_X}(k)$	.05	.16	-0.05	-0.17	.00	.11	.07	.19	.21	.15	.00	.02	.11
k	-13	-14	-15	-16	-17	-18	-19	-20	-21	-22	-23	-24	
$r_{\hat{e}_Y \hat{e}_X}(k)$	-0.05	-0.03	-0.05	-0.08	-0.19	-0.02	-0.14	-0.01	.01	.06	.15	.06	.11

Tabelle 69

Diagnostic Checks der identifizierten und geschätzten
Transferfunktion-Form für den ICS

Q'	df	$\chi^2_{.05}$	$\chi^2_{.10}$
16.0	22	33.9	30.8
S'			
16.8	22	33.9	30.8
S''			
23.2	24	36.4	33.2

Legende:

df Zahl der Freiheitsgrade;

Q', S', vgl. Abschnitt 535.

S''

Die $r_{\hat{e}_Y \hat{e}_Y}(k)$ und $r_{\hat{e}_Y \hat{e}_X}(k)$ liegen jeweils flach um die 0-Achse; von einzelnen Ausreißern, die auf Stichprobenvariation zurückzuführen sein dürften, abgesehen. Da auch die Q'-, S'- und S''-Statistiken alle unterhalb des kritischen Wertes der Chi-Quadrat-Verteilung, berichtigt für die jeweilige Zahl der Freiheitsgrade, sind (Irrtumswahrscheinlichkeit .10), kann die Adäquanz der identifizierten und geschätzten Transferfunktion-Form als bestätigt gelten.

57 Zusammenfassung der Ergebnisse des zweiten Teils der
empirischen Analyse

Die wesentlichen Ergebnisse des zweiten Teils der empirischen Analyse sind bereits in den Abschnitten 5623, 56331 und 56332 stichwortartig aufgeführt; die folgende Zusammenfassung ist dazu als Ergänzung zu verstehen.

1. Die auf der iterativen Strategie von Box/Jenkins und Granger/Newbold beruhende Analyse der Beziehungen des ICS zu ökonomischen Variablen hat keine deutlichen Hinweise auf stark ausgeprägte Zusammenhänge ergeben. In der auf die transformierten Serien zurückgreifenden Kausalitätsanalyse (vgl. die Tabellen 50 - 60) dominiert das Erscheinungsbild überwiegend flacher Kreuzkorrelogramme. Treten nennenswerte Kreuzkorrelationen auf, verweisen sie im allgemeinen auf die Kurzfristigkeit der Beziehungen. Dabei erschweren die häufig für Lag $k = 0$ gemessenen Koeffizienten eine zweifelsfreie Feststellung der Richtung der Kausalität.
2. Die Vorzeichen der Kreuzkorrelationen der transformierten Reihen bestätigen im allgemeinen die Lehren der "Psychological Economics", wonach das Konsumklima positiv korreliert ist mit diskretionären Konsumausgaben und negativ korreliert mit Indikatoren der Inflations- und Arbeitslosigkeitsentwicklung.
3. Die identifizierten und geschätzten Transferfunktion-Formen, die den ICS alternativ als unabhängige und als abhängige Variable behandeln, sind durch nach wenigen Quartalen schnell absinkende Lag-Verteilungen der jeweils unabhängigen Variablen sowie durch sparsame Parametrisierung der Noise-Modelle gekennzeichnet. Trotz ihrer einfachen Struktur sind die Noise-Modelle für die Prognose der je-

weils abhängigen Variablen von Bedeutung; ihre Nichtberücksichtigung dürfte zu überhöhten Fehlervarianzen führen.

4. Als Ergebnis der der Kausalitätsanalyse vorgeschalteten Transformation zu weißem Rauschen ist auf die regelmäßig hohe Autokorrelation in allen berücksichtigten Reihen - die sich auch in der Notwendigkeit zu mindestens einmaligem Differenzieren äußert - zu verweisen. Dieser Sachverhalt rechtfertigt im besonderen die Aufmerksamkeit, die im zweiten Teil der empirischen Analyse der autokorrelativen Struktur der Reihen vor Identifikation und Schätzung der Transferfunktion-Form geschenkt wird.

Es ist ferner die Ähnlichkeit der für die ökonomischen Reihen sowie den ICS identifizierten und geschätzten univariaten ARIMA-Modelle festzuhalten. Diese Ähnlichkeit könnte im Sinne der Argumentation in Abschnitt 52 als Hinweis auf die Zusammengehörigkeit der Reihen in der Form eines ökonometrischen Modells verstanden werden.

6 Abschließende Bemerkungen und Ausblick

Die vorliegende Untersuchung unterscheidet sich von den bisherigen zum Problem der Beziehung des ICS zu ökonomischen Variablen durch die Betonung von Aspekten wie der effizienten Schätzung von Regressionsmodellen, der Berücksichtigung des Noise-Modells bei der Erzeugung von Post-Sample-Prognosen, der Wahl geeigneter "naiver" Modelle, die als Maßstab der Prognosegüte dienen, sowie der Identifikation und Schätzung von Repräsentationsformen bivariater ARIMA-Modelle.

Nicht in allen Fällen war es im Laufe der Untersuchung möglich, Sonderproblemen, die nicht unmittelbar den Gang der Argumentation betrafen, gebührende Aufmerksamkeit zu schenken. Dies sei hier für einige als wesentlich angesehene Probleme nachgeholt. Schließlich sind einige mögliche Ansätze für die weitere Erforschung des Zusammenhangs zwischen dem ICS und ökonomischen Variablen aufgezeigt.

1. Die Eignung des Differenzenfilters $(1 - B)^d$ zur Beseitigung von Nichtstationarität dürfte - insbesondere für einige der berücksichtigten ökonomischen Variablen - Zweifeln begegnen.

Bekanntlich werden bestimmte Formen des Trends bei Anwendung des Differenzenfilters aus den Originalwerten beseitigt;¹⁾ insoweit die im zweiten Teil der empirischen Analyse berücksichtigten ökonomischen Variablen solche Trend-Komponenten aufweisen, bleibt deren Erzeugungsmechanismus im Rahmen der iterativen Strategie von Box/Jenkins und Granger/Newbold

1) Vgl. Stöwe (1977), S. 299.

unaufgeklärt. Darüberhinaus führt die d-fache Differenzenbildung dann zu ineffizienten Schätzungen, wenn der Erzeugungsmechanismus der Originalwerte nicht zumindestens approximiert durch homogene Nichtstationarität der Ordnung d gekennzeichnet ist.¹⁾ Diese Situation könnte z.B. für $IMPR_t$ gegeben sein; die hier angetroffene Form der Nichtstationarität könnte vielleicht eher durch logarithmische Transformation - möglicherweise mit anschließender Differenzenbildung - denn durch Anwendung des Differenzenfilters $(1 - B)^d$ auf die Originalwerte adäquat beseitigt werden.

Diesen Einwänden muß entgegen gehalten werden, daß die Verwendung unterschiedlicher Transformationsverfahren zur Beseitigung der in den Reihen auftretenden Nichtstationarität schwer zu bewältigende Probleme für die Anwendung der iterativen Strategie von Box/Jenkins und Granger/Newbold, insbesondere die Kreuzkorrelogramm-Analyse aufwirft. Die Vorteile eines für alle Reihen einheitlichen Verfahrens sollten hier die in einigen Fällen möglichen Nachteile überwiegen, zumal - wie in Abschnitt 421 festgestellt - noch keine umfassende Konzeption für die Behandlung der in ökonomischen Reihen anzutreffenden Form von Nichtstationarität vorliegt.

2. Der Transformation zu weißem Rauschen vor Berechnung des Kreuzkorrelogramms - die eng verknüpft ist mit der Kausalitäts-Konzeption von Granger - liegt der Gedanke zugrunde, die Analyse der Beziehungen zwischen den Reihen frei zu halten von den möglicherweise Zusammenhänge vortäuschenden Eigenschaften der Kreuzkorrelationen bzw. den Schätzungen der Kreuzkorrelationen autokorrelierter Prozesse. Das Verfahren der Transformation zu weißem Rauschen dient also dazu, die

1) Vgl. Stöwe (1977), S. 299.

Aufdeckung von Schein-Kausalität ("spurious regression"), d.h. von Kausalität, die nicht wirklich existiert, zu verhindern.¹⁾

Theoretisch bleiben aufgrund der Linearität der Transformation von Y_t und X_t zu U_t und V_t mithilfe der Operatorpolynome $a_Y(B)b_Y^{-1}(B)$ bzw. $a_X(B)b_X^{-1}(B)$ (vgl. Gleichung (5.23)) die Beziehungen zwischen Y_t und X_t unberührt, d.h. die $r_{UV}(k)$ enthalten in bezug auf die Kausalmuster zwischen Y_t und X_t alle notwendigen Informationen.²⁾

Gegenüber dem Verfahren der Transformation zu weißem Rauschen wird jedoch der Vorwurf erhoben, es führe in der Praxis - in der nicht die Prozesse Y_t und X_t , sondern nur deren Realisationen y_t und x_t bekannt sind - zugleich zur Aufdeckung von Schein-Unabhängigkeit ("spurious indepenence"), d.h. von Unabhängigkeit, die nicht wirklich existiert. Die zwischen zwei (autokorrelierten) Reihen Y_t und X_t bestehenden Beziehungen spiegelten sich also nicht oder nur unzureichend in den Kreuzkorrelationen $r_{\hat{u}\hat{v}}(k)$ der Schätzungen der transformierten Serien wider.³⁾

Tatsächlich ist die Verteilung der $r_{\hat{u}\hat{v}}(k)$ nur für den Fall der Unabhängigkeit der zugrundeliegenden Reihen Y_t und X_t bekannt;⁴⁾ sie entspricht dann asymptotisch der Verteilung der $r_{uv}(k)$, die berechnet werden könnten, wenn die wahren Parameter der zur Transformation verwendeten Operatorpoly-

1) Vgl. Pierce/Haugh (1977), S. 290.

2) S. auch Granger (1977), S. 22: "In theory, the prewhitening procedure should not affect the outcome. The natural measure of the extent to which two variables are related is the coherence function from cross-spectral analysis, and the size and shape of this function is unaffected by applying filters to the two series involved". Vgl. auch Pierce/Haugh (1977), S. 270.

3) Vgl. Pierce/Haugh (1977), S. 290.

4) Vgl. Pierce (1977), S. 15.

nome bekannt wären. Falls die Nullhypothese der Unabhängigkeit von Y_t und X_t falsch ist, folgen die $r_{\hat{u}\hat{v}}(k)$ jedoch nicht mehr approximiert der gleichen Verteilung wie die $r_{uv}(k)$ (die ihrerseits nicht mehr die Verteilungseigenschaften von Kreuzkorrelationen unabhängiger Prozesse besitzen).¹⁾ Im allgemeinen wird die Signifikanz der $r_{\hat{u}\hat{v}}(k)$ dann bei Zugrundelegung eines Standardfehlers von $T^{-1/2}$ unterschätzt: "The ... effect can be shown to result in an underestimation of significance, i.e., a tendency not to detect causality when it exists."²⁾ Der im zweiten Teil der empirischen Analyse verwendete Test der Nullhypothese der Unabhängigkeit der Reihen mithilfe der S_K -Statistik dürfte somit einen relativ großen Fehler zweiter Art aufweisen.³⁾

Die Tatsache, daß das Verfahren der Transformation zu weißem Rauschen eine Tendenz zur Beseitigung von Kausalität, d.h. zur Aufdeckung von Schein-Unabhängigkeit besitzt, sollte für sich genommen nicht zu seiner Ablehnung führen. Zunächst wird die Nützlichkeit der Transformation zu weißem Rauschen durch ihre Integrierbarkeit in die iterative Strategie von Box, Jenkins und Granger/Newbold unterstrichen. Darüberhinaus muß ihre Eignung an der Fähigkeit anderer Verfahren, die Beziehungen zwischen Zeitreihen aufzudecken, gemessen werden. Obwohl es an dieser Stelle nicht möglich ist, die Eigenschaften solcher Verfahren zu würdigen,⁴⁾ seien hier Zweifel an der Existenz eines "idealen" Verfahrens - eines Verfahrens, das weder dem Problem der Aufdeckung von Schein-Kausalität noch dem der Aufdeckung von Schein-Unab-

1) Vgl. Pierce/Haugh (1977), S. 284.

2) Ibid.

3) S. auch Sims (1977), S. 23: "... makes the tests asymptotically biased for any null hypothesis except the null hypothesis of no relation between the series".

4) Die Eigenschaften einer Reihe anderer Verfahren sind bei Pierce/Haugh (1977), S. 279 ff., beschrieben.

hängigkeit offen ist - geäußert.¹⁾

Angesichts der Tendenz der bisherigen Untersuchungen zur Beziehung des ICS zu ökonomischen Variablen, die Aufdeckung von Schein-Kausalität zu begünstigen (vgl. Abschnitt 2), erfährt die Verwendung eines Verfahrens, das - wie die iterative Strategie von Box/Jenkins und Granger/Newbold - zur Aufdeckung von Schein-Unabhängigkeit neigen könnte, eine besondere Berechtigung. Jedenfalls dürfen die Ergebnisse eines Verfahrens, das der Aufdeckung von Beziehungen nicht förderlich ist, in jenen Fällen als sehr aussagekräftig bezeichnet werden, in denen die Existenz von Beziehungen zu bestätigen ist.

3. Um Mißverständnissen vorzubeugen, ist eine Abgrenzung der Konzeption der Granger-Kausalität von dem herkömmlichen Kausalitäts-Begriff, der eine Ursache-Wirkungs-Beziehung beschreibt, erforderlich.

Die Statuierung einer der in Abschnitt 5321 vorgestellten Formen von Granger-Kausalität ist stets von der verwendeten Informations-Menge abhängig. So könnte z.B. für eine Informations-Menge I_1 einfache Granger-Kausalität aufgedeckt werden, die für eine Informations-Menge I_2 nicht zu bestätigen wäre. Ein Beispiel mag diesen Gedanken verdeutlichen.²⁾ Es gelte:

$$(6.1) \quad \sigma^2(X_t | I_{\bar{X}_t}) > \sigma^2(X_t | I_{\bar{X}_t}, \bar{Z}_t)$$

1) Nach Pierce/Haugh hängt das Ausmaß der Aufdeckung von Schein-Kausalität bzw. Schein-Unabhängigkeit von der Sensibilität ab, mit der ein Verfahren auf die autokorrelative Struktur der Reihen reagiert: "The real difference would seem to be in how autocorrelation problems (the univariate series structures) are handled. If the procedures are not geared to the particular series ... , "spurious regressions" can result; if they are, "spurious independence" may on occasion occur." Pierce/Haugh (1977), S. 290.

2) Zur Notation vgl. Abschnitt 5321.

$$\sigma^2(Y_t | I_{\bar{Y}_t}) > \sigma^2(Y_t | I_{\bar{Y}_t}, \bar{Z}_t)$$

$$\sigma^2(X_t | I_{\bar{X}_t}, \bar{Z}_t) = \sigma^2(X_t | I_{\bar{X}_t}, \bar{Y}_t, \bar{Z}_t)$$

$$\sigma^2(X_t | I_{\bar{X}_t}) > \sigma^2(X_t | I_{\bar{X}_t}, \bar{Y}_t)$$

Im Rahmen einer Informations-Menge, die $\bar{X}_t$, $\bar{Y}_t$ und $\bar{Z}_t$ einschließt, übt Z_t einfachen Granger-kausalen Einfluß auf X_t und Y_t aus, während von Y_t kein einfacher Granger-kausaler Einfluß auf X_t ausgeht. Für eine Informations-Menge, die nur $\bar{X}_t$ und $\bar{Y}_t$ umfaßt, kann hingegen ein einfacher Granger-kausaler Einfluß von Y_t auf X_t "aufgedeckt" werden, denn Y_t enthält Informationen über den fehlenden Prozeß Z_t , die zur Prognose von X_t verwendet werden können. Y_t besitzt hier natürlich nur deswegen Informationen zur Prognose von X_t , weil Z_t aus der Informations-Menge ausgeschlossen ist.

Dieses Beispiel verweist auf die Notwendigkeit, die Ergebnisse einer auf der Konzeption der Granger-Kausalität basierenden Analyse stets auf die berücksichtigte Informations-Menge zu beziehen.¹⁾

Die im zweiten Teil der empirischen Analyse verwendeten Informations-Mengen umfassen jeweils nur zwei Reihen. Informations-Mengen dieses geringen Umfangs werden in der Regel nicht ausreichen, eine adäquate Beschreibung des zwischen ökonomischen und psychologischen Variablen bestehenden Zusammenhanges zu ermöglichen. So darf vermutet werden, daß die zwischen dem ICS und den berücksichtigten ökonomischen Variablen aufgedeckten Formen von Granger-Kausalität

1) S. auch Granger/Newbold (1977), S. 225: "Thus, one should properly speak of "causality with respect to the particular I_t used"". Vgl. auch in diesem Sinne Granger (1969), S. 429, Pierce/Haugh (1977), S. 291.

zumindestens in Teilen rein korrelative Zusammenhänge benennen, die z.B. durch die gemeinsame Abhängigkeit von dritten, unbekannten Variablen bedingt sind.

Die Lösung dieses Problems ist nicht durch die Einbeziehung zusätzlicher Variablen in die zugrundeliegenden Informations-Mengen zu garantieren. Stets bleibt die Möglichkeit der Nichtberücksichtigung von für das Ursachengefüge relevanten Variablen offen. Darüberhinaus verfügen größere Informations-Mengen - wie der Vergleich univariater ARIMA-Modelle und ökonometrischer Modelle in Tabelle 3 zeigt - nicht notwendigerweise über eine überlegene Prognosegüte.

Da das in der Problemstellung definierte Interesse dieser Untersuchung in der Prognostizierbarkeit diskretionärer Konsumausgaben durch den ICS sowie der Prognostizierbarkeit des ICS selbst durch ökonomische Variablen liegt - und nicht in der Spezifikation von Modellen für Kontrollzwecke oder die Simulation der Konsequenzen unterschiedlicher Handlungsalternativen -, ist die Aufdeckung überwiegend korrelativer Zusammenhänge kein störender Faktor.

4. In einigen Untersuchungen¹⁾ ist eine transformierte Version des ICS zur Prognose diskretionärer Konsumausgaben in Modelle zur Prognose diskretionärer Konsumausgaben integriert. Die Transformations-Regel lautet:²⁾

$$(6.2) \quad ICS_t^{tr} = .50(1 - B)ICS_{t-1} + .50(1 - B)ICS_{t-2}$$

falls (a) $(1 - B)ICS_{t-k}$ für $k = 1, 2, 3$ das gleiche Vorzeichen besitzt oder

1) Vgl. Hymans (1970), Juster/Wachtel (1972b), Shapiro (1972).

2) Vgl. Shapiro (1972), S. 382 f.

(b) $(1 - B)ICS_{t-i}$ für $i = 1, 2$ das gleiche Vorzeichen besitzen und

$$|(1 - B)_{t-1} + (1 - B)ICS_{t-2}| \geq 7.$$

$ICS_t^{tr} = 0$ falls weder (a) noch (b) zutrifft.

Der dieser Transformation zugrundeliegende Gedanke ist, nur solche Bewegungen des ICS zu berücksichtigen, die nicht als rein zufällig, sondern längerfristig andauernd angesehen werden können.

Auffallend ist, daß diese Transformation im Vergleich zu dem im zweiten Teil der empirischen Analyse verwendeten Verfahren eine Reihe produziert, die ein höheres Maß an Autokorrelation als die Originalwerte des ICS aufweisen dürfte. Die Einbeziehung einer nach Maßgabe von Gleichung (6.2) transformierten ICS-Reihe in Modelle zur Prognose diskretionärer Konsumausgaben sollte daher den Problemen der Autokorrelation der stochastischen Größe bei der Schätzung besondere Aufmerksamkeit schenken. Es muß bezweifelt werden, ob z.B. die Ergebnisse von Juster/Wachtel - die transformierte ICS-Reihe besitzt dort in der Sample-Periode eine höhere Prognosegüte als die nicht transformierte ¹⁾, für ein anderes als das OLS-Schätzverfahren Bestand haben. ²⁾

5. Die Ergebnisse dieser Untersuchung erlauben einige Hinweise auf die möglichen Schwerpunkte der zukünftigen empirischen Erforschung des Verhältnisses des ICS zu ökonomischen Variablen.

Es dürfte zweckmäßig sein, bei Schätzungen von Modellen, die

1) Vgl. Juster/Wachtel (1972b), S. 331.

2) Aufschlußreich ist, daß der nach Maßgabe von Gleichung (6.2) transformierte ICS in einer Post-Sample-Evaluierung schlechter als der nicht transformierte ICS abschnitt. Vgl. Adams/Klein (1972).

die Beziehung des ICS zu ökonomischen Variablen beschreiben eine von weißem Rauschen abweichende autokorrelative Struktur der stochastischen Größe zu unterstellen. Die Zeitreihennatur des ICS und der meisten ökonomischen Reihen ist durch hohe Autokorrelation, vermutlich sogar Nichtstationarität gekennzeichnet, die sich regelmäßig in der stochastischen Größe widerspiegeln wird. Von der Anwendung des OLS-Verfahrens muß daher im allgemeinen abgeraten werden. Die in der Sample-Periode erkannte autokorrelative Struktur der stochastischen Größe sollte dann - gemeinsam mit dem effizient geschätzten Parameter-Vektor - bei der Erstellung von Post-Sample-Prognosen berücksichtigt werden.

Die Prognosen "naiver" Modelle empfehlen sich als Maßstab der Prognosegüte in Post-Sample-Bewertungen. Im allgemeinen bieten sich hierfür univariate ARIMA-Modelle an, identifiziert und geschätzt mithilfe der iterativen Strategie von Box/Jenkins. Sie sind den in den bisherigen Untersuchungen verwendeten aufgrund der angemesseneren Repräsentation der autokorrelativen Struktur der zu prognostizierenden Variablen vorzuziehen.

Bivariate ARIMA-Modelle, identifiziert und geschätzt mithilfe der iterativen Strategie von Box/Jenkins und Granger/Newbold, sollten als wichtiger Bezugspunkt für die Spezifikation von Prognosemodellen dienen. Ihre Nützlichkeit liegt einmal in der Betonung des dynamischen Charakters der Beziehungen des ICS zu ökonomischen Variablen, der gekennzeichnet ist durch die Lag-Verteilungen der vorherbestimmten Variablen und durch das Noise-Modell. Zum anderen ist ihre Fähigkeit nennenswert, Prognosen der jeweils abhängigen Va-

riablen für beliebige Prognosedistanzen erzeugen zu können: ihre Spezifikation schließt auch den Generierungsmechanismus der unabhängigen Variablen ein, üblicherweise in der Form eines univariaten ARIMA-Modells. Die in der Problemstellung dieser Untersuchung angesprochene Schwierigkeit der Prognostizierbarkeit des ICS wäre damit theoretisch auch für jenen Fall zu lösen, in dem keine Erkenntnisse über die Abhängigkeiten des ICS zur Verfügung stünden.

Die Grenzen eines ausschließlich auf der iterativen Strategie von Box/Jenkins und Granger/Newbold basierenden Ansatzes sind durch die Beschränkung auf wenige, meist zwei Reihen gegeben. Eine verstärkte Einbeziehung der ökonomischen Theorie könnte zu einer Ausweitung dieser Grenzen beitragen: die Theorie der "Psychological Economics" sollte sich um eine zumindestens grobe Ausarbeitung der dynamischen Eigenschaften von Modellen, die die Einfügung des ICS in das Kausalgefüge ökonomischer Variablen beschreiben, bemühen - sie könnte z.B. die Existenz von Lags der vorherbestimmten Variablen oder eine von weißem Rauschen abweichende autokorrelative Struktur des Noise-Modells postulieren, ohne deren exakte Form zu bestimmen -, während die iterative Strategie von Box/Jenkins und Granger/Newbold zu einer Ergänzung und Verfeinerung der von der Theorie vorgelegten dynamischen Spezifikation beitragen könnte. In diesem Sinne ist es gerechtfertigt, von einer wünschenswerten Vereinigung des ökonometrischen und des zeitreihentheoretischen Ansatzes zu sprechen.

Zusammenfassung

Ziel der Untersuchung ist die Beantwortung der Frage, ob - und, falls ja, wie - der "Index of Consumer Sentiment" (ICS) in Modelle zur Prognose US-amerikanischer diskretionärer Konsumausgaben integriert werden sollte. Dabei ist auch dem Problem der Prognostizierbarkeit des ICS selbst, von dessen Lösung die Erstellung von Prognosen für größere Prognose-
distanzen abhängt, Aufmerksamkeit geschenkt.

In Abschnitt 1 wird die Definition sowie der theoretische Hintergrund des ICS vorgestellt. Dabei wird festgehalten, daß die Theorie der "Psychological Economics" keine näheren Angaben über die Spezifikation von Modellen, die die Beziehung des ICS zu ökonomischen Variablen beschreiben, macht.

Die bisherigen Untersuchungen erfahren in Abschnitt 2 eine kritische Würdigung. Die Schwerpunkte der Kritik sind:

- Die verwendeten Modelle berücksichtigen die autokorrelative Struktur der jeweiligen stochastischen Größe in nicht immer ausreichendem Maße. Dies äußert sich in:
 - der fehlerhaften Interpretation von Ergebnissen des OLS-Schätzverfahrens;
 - der Erstellung suboptimaler Post-Sample-Prognosen durch Verwendung eines ineffizient geschätzten Parameter-Vektors und/oder Nichtberücksichtigung des Noise-Modells.
- Die als Maßstab der Güte von Prognosemodellen für diskretionäre Konsumausgaben benutzten "naiven" Modelle sind regelmäßig nicht in bestmöglicher Weise der autokorrelativen Struktur der Reihen ange-

paßt. Ihre Prognosen stellen daher einen ungeeigneten Maßstab dar.

- Die aufgeführten Modelle sind durch "trial and error"-Verfahren, d.h. ohne Rückgriff auf die ökonomische Theorie oder systematische zeitreihenanalytische Verfahren spezifiziert. Der zufallsbedingte Charakter dieses Vorgehens eröffnet die Modelle dem Vorwurf der Misspezifikation in besonderem Maße.

Der in Abschnitt 3 entwickelte eigene Ansatz trägt dieser Kritik Rechnung. Er basiert auf zwei empirischen Teilen.

Der erste empirische Teil untersucht die prognostizistische Bedeutung des ICS für diskretionäre Konsumausgaben in einer Post-Sample-Periode, wobei auf Modelle von Mueller und Fair zurückgegriffen wird. Die Elemente des ersten empirischen Teils, die in Abschnitt 4 detailliert vorgestellt werden, sind:

- die Schätzung der Parameter-Vektoren mithilfe von im Vergleich zum OLS-Verfahren effizienteren Verfahren;
- die Berücksichtigung der in der Sample-Periode erkannten autokorrelativen Struktur der stochastischen Größe bei der Erstellung der Post-Sample-Prognosen;
- die Verwendung "naiver" Modelle, die mithilfe der von Box/Jenkins für die Identifikation und Schätzung univariater ARIMA-Modelle entwickelten iterativen Strategie spezifiziert sind.

Als wesentliche Ergebnisse des ersten empirischen Teils können festgehalten werden:

- Der ICS besitzt in der Sample-Periode einen knapp signifikanten Erklärungswert, wenn die Schätzung der autokorrelativen Struktur der stochastischen Größe Rechnung trägt.
- In der Post-Sample-Periode sind die Prognosen der den ICS einschließenden Modelle denen der "naiven" Modelle überlegen. Dies erscheint bemerkenswert, da univariate ARIMA-Modelle gute Ergebnisse in Vergleichen mit ökonometrischen Modellen vorweisen können.
- Die Überlegenheit der Prognosen der den ICS einschließenden Modelle ist im wesentlichen auf die Berücksichtigung des Noise-Modells bei der Erstellung der Prognosen zurückzuführen.

Der zweite empirische Teil bemüht sich um die Identifikation und Schätzung von Repräsentationsformen bivariater ARIMA-Modelle mithilfe der von Box/Jenkins und Granger/Newbold empfohlenen iterativen Strategie. Als methodische Besonderheit dieses in Abschnitt 5 vorgestellten Verfahrens kann die Transformation der Reihen zu Realisationen von weißem Rauschen vor Berechnung des für die Identifikation wesentlichen Kreuzkorrelogramms bezeichnet werden. Ziel der Anwendung des Verfahrens ist die Spezifikation der Lag-Verteilung und des Noise-Modells in Modellen, die (a) den ICS als

unabhängige Variable zur Prognose diskretionärer Konsumausgaben und (b) den ICS als abhängige Variable aufführen. Im letzteren Fall sind als unabhängige Variable jeweils ökonomische Variablen, die in den bisherigen Untersuchungen verwendet sind, berücksichtigt.

Die wesentlichen Ergebnisse des zweiten empirischen Teils sind:

- Zwischen dem ICS und den berücksichtigten ökonomischen Variablen lassen sich nur relativ schwache Beziehungen aufdecken, wenn ein Verfahren verwendet wird, das der autokorrelativen Struktur der Reihen Rechnung trägt.
- Das relativ häufige Auftreten simultaner Beziehungen erschwert die Spezifikation von Modellen, die ein eindeutiges Kausalverhältnis zugrundelegen.
- Die identifizierten und geschätzten Modelle - die den ICS als unabhängige Variable zur Prognose von Gebrauchsgüter- und Autoausgaben und als abhängige Variable, erklärt durch die Inflationsrate, aufführen - sind durch schnell absinkende Lag-Verteilungen der unabhängigen Variablen und relativ sparsame Parametrisierung der Noise-Modelle gekennzeichnet.

Ausblickend auf mögliche Schwerpunkte der zukünftigen Forschung zur Beziehung des ICS zu ökonomischen Variablen wird in Abschnitt 6 eine Integration der Theorie der "Psychological Economics" und der von Box/Jenkins und Granger/Newbold empfohlenen iterativen Strategie zum Zwecke der Spezifikation von Modellen für wünschenswert erklärt.

Literaturverzeichnis

- Adams, F.C., Green, E.W. (1965)
Explaining and Predicting Aggregative Consumer Attitudes; International Economic Review, 6, S. 275.
- Adams, F.G., Klein, L.R. (1972)
Anticipations Variables in Macro-Econometric Models; in: Strumpel/Morgan/Zahn (1972), S. 289.
- Anderson, O.D. (1975)
Time Series Analysis and Forecasting: The Box-Jenkins Approach; London.
- Ando, A., Palash, C. (1977)
Some Stabilization Problems of 1971 - 75, with an Application of Optimal Control Algorithms; in: Intriligator (1977), S. 783.
- Ashley, R., Granger, C.W.J., Schmalensee, R. (1977)
Advertising and Aggregate Consumption: An Analysis of Causality; Discussion Paper 77-9, Department of Economics, University of California, San Diego.
- Bartlett, M.S. (1962)
An Introduction to Stochastic Processes; Cambridge.
- Box, G.E.P., Cox, D.R. (1964)
An Analysis of Transformations; Journal of Royal Statistical Society, B, 26, S. 211.
- Box, G.E.P., Jenkins, G. (1976)
Time Series Analysis: Forecasting and Control; San Francisco.
- Burch, S.W., Stekler, H.O. (1969)
The Forecasting Accuracy of Consumer Attitude Data; Journal of the American Statistical Association, 64, S. 1225.

Chatfield, C., Prothero, D.L. (1973a)
Box-Jenkins Seasonal Forecasting: Problems in
a Case-Study; Journal of Royal Statistical
Society, A, 136, S. 295.

Chatfield, C., Prothero, D.L. (1973b)
Reply; Journal of Royal Statistical Society, A,
136, S. 345.

Christ, C.F. (1975)
Judging the Performance of Econometric Models
of the U.S. Economy; International Economic Review,
16, S. 34.

Cooper, R.L. (1972)
The Predictive Performance of Quarterly Econometric
Models of the United States; in: Hickman (1972),
S. 813.

Cooper, J.P., Nelson, C.R. (1975)
The Ex Ante Prediction Performance of the St. Louis
and F.R.B.-M.I.T.-Penn. Econometric Models and Some
Results on Composite Predictors; Journal of
Money, Credit and Banking, 7, S. 1.

Cramer, R.H., Miller, R.B. (1976)
Dynamic Modelling of Multivariate Time Series
for Use in Bank Analysis; Journal of Money,
Credit and Banking, 8, S. 85.

Curtin, R.T. (1973)
Index Construction: An Appraisal of the Index
of Consumer Sentiment; in: Mandell/Katona (1973),
S. 253.

Curtin, R.T. (Hrsg.) (1976)
Surveys of Consumers 1974-1975; Ann Arbor.

Dhrymes, P.J. (1974)
Econometrics; New York.

Dhrymes, P.J. et al. (1972)
Criteria for Evaluation of Econometric Models;
Annals of Economic and Social Measurement, 1, S. 291.

Draper, N.R., Smith, H. (1966)
Applied Regression Analysis; New York.

Duesenberry, J.S., Fromm, G., Klein, L.R.,
Kuh, E. (Hrsg.) (1965)
The Brookings Quarterly Econometric Model of the
United States; Amsterdam.

Durbin, J. (1960)
Estimation of Parameters in Time-Series Regression
Models; Journal of Royal Statistical Society, B,
22, S. 139.

Durbin, J. (1970)
Testing for Serial Correlation in Least Squares
Regression When Some of the Regressors are Lagged
Dependent Variables; Econometrica, 38, S. 410.

Evans, M.K., Haitovsky, Y., Treyz, G.I. (1972)
An Analysis of the Forecasting Properties of
U.S. Econometric Models; in: Hickman (1972).

Evans, M.K., Klein, L.R. (1968)
The Wharton Econometric Forecasting Model;
University of Pennsylvania.

Fair, R.C. (1971)
A Short-Run Forecasting Model of the United States
Economy; Lexington.

Fair, R.C. (1974)
An Evaluation of a Short-Run Forecasting Model;
International Economic Review, 15, S. 285.

Friend, I., Adams, F.G. (1964)
The Predictive Ability of Consumer Attitudes,
Stock Prices, and Non-Attitudinal Variables;
Journal of the American Statistical Association,
59, S. 987.

- Friend, I., Jones, R.C. (1964)
Short Run Forecasting Models Incorporating
Anticipation Data; in: o. V., Models of
Income ... (1964), S. 279.
- Goldberger, A.S. (1962)
Best Linear Unbiased Prediction in the
Generalized Linear Regression Model; Journal of
the American Statistical Association, 57, S. 369.
- Goldfeld, F.M. (1972)
Discussion; in: Hickman (1972), S. 927.
- Granger, C.W.J. (1969)
Investigating Causal Relations by Econometric
Models and Cross-Spectral Methods; Econometrica,
37, S. 424.
- Granger, C.W.J. (1977)
Comment; Journal of the American Statistical
Association, 72, S. 22.
- Granger, C.W.J., Hatanaka, M. (1964)
Spectral Analysis of Economic Time Series;
Princeton 1964.
- Granger, C.W.J., Newbold, P. (1973)
Some Comments on the Evaluation of Economic
Forecasts; Applied Economics, 5, S. 35.
- Granger, C.W.J., Newbold, P. (1974)
Spurious Regression in Econometrics; Journal
of Econometrics, 2, S. 111.
- Granger, C.W.J., Newbold, P. (1976)
Identification of Two-Way Causal Systems;
in: Intriligator (1976), S. 337.
- Granger, C.W.J., Newbold, P. (1977)
Forecasting Economic Time Series; New York.

- Green, G.R., Liebenberg, M., Hirsch, A.A. (1972)
Short- and Long-Term Simulations with the OBE
Econometric Model; in: Hickman (1972), S. 101.
- Griliches, Z., Rao, P. (1969)
Small-Sample Properties of Several Two-Stage
Regression Methods in the Context of Autocorrelated
Errors; Journal of the American Statistical
Association, 64, S. 253.
- Hannan, E.J. (1970)
Multiple Time Series; New York.
- Haugh, L.D. (1976)
Checking the Independence of Two Covariance-
Stationary Time Series: A Univariate Residual
Cross-Correlation Approach; Journal of the
American Statistical Association, 71, S. 378.
- Haugh, L.D., Box, G.E.P. (1977)
Identification of Dynamic Regression (Distributed
Lag) Models Connecting Two Time Series; Journal
of the American Statistical Association, 72,
S. 121.
- Hickman, B.G. (Hrsg.) (1972)
Econometric Models of Cyclical Behavior, New York.
- Hirsch, A.A., Grimm, B.T., Narasimham, G.V.L. (1974)
Some Multiplier and Error Characteristics of the
B.E.A. Quarterly Model; International Economic
Review, 15, S. 616.
- Howrey, E.P., Klein, L.R., McCarthy, M.D. (1974)
Notes on Testing the Predictive Performance of
Econometric Models; International Economic
Review, 15, S. 366.
- Hymans, S.H. (1970)
Consumer Durable Spending: Explanation and
Prediction; in: Brookings Papers on Economic
Activity, S. 173.

Intriligator, M.D. (Hrsg.) (1976)
Frontiers of Quantitative Economics; Vol. IIIa,
New York.

Intriligator, M.D. (Hrsg.) (1977)
Frontiers of Quantitative Economics; Vol. IIIb,
New York.

Jenkins, G.M., Watts, D.G. (1968)
Spectral Analysis and Its Applications; San
Francisco.

Johnston, S.J. (1972)
Econometric Methods; New York.

Jorgenson, D.W. (1966)
Rational Distributed Lag Functions; *Econometrica*,
32, S. 135.

Juster, F.T. (1969)
Consumer Anticipations and Models of Durable
Goods Demand; in: Mincer (1969), S. 176.

Juster, F.T., Wachtel, P. (1972a)
Anticipatory and Objective Models of Durable
Goods Demand; *American Economic Review*, 62,
S. 564.

Juster, F.T., Wachtel, P. (1972b)
Uncertainty, Expectations, and Durable
Goods Demand Models; in: Strumpel/Morgan/Zahn
(1972), S. 321.

Kashyap, R.L., Rao, A.R. (1976)
Dynamic Stochastic Models from Empirical
Data; New York.

Katona, G. (1951)
Psychological Analysis of Economic Behavior;
New York.

Katona, G. (1957)
Federal Reserve Board Committee Reports
on Consumer Expectations and Saving
Statistics; Review of Economics and
Statistics, 39, S. 41.

Katona, G. (1960)
The Powerful Consumer, New York.

Katona, G. (1964)
The Mass Consumption Society, New York.

Katona, G. (1967a)
Anticipations Statistics and Consumer
Behavior; The American Statistician, 21,
S. 24.

Katona, G. (1967b)
What is Consumer Psychology?; American
Psychologist, 22, S. 219.

Katona, G. (1968)
Consumer Behavior: Theory and Findings
on Expectations and Aspirations; American
Economic Review; 58, S. 19.

Katona, G. (1972)
Theory of Expectations; in: Strumpel/Morgan/
Zahn (1972), S. 549.

Katona, G. (1975)
Psychological Economics; Amsterdam.

Katona, G. (1976)
Understanding Consumer Attitudes; in: Curtin
(1976), S. 203.

Katona, G., Mueller, E. (1956)
Consumer Expectations 1953 - 1956; Ann Arbor.

Katona, G., Mueller, E. (1961)
The Function of Expectational and Motivational
Data; in: Survey Research Center (1961), S. 171.

Katona, G., Strumpel, B., Zahn, E. (1971)
Aspiration and Affluence; New York.

Klein, L.R. (1968)
An Essay on the Theory of Economic Prediction;
Helsinki.

Klein, L.R. (1977)
Economic Policy Formation Through the Medium
of Econometric Models; in: Intriligator (1977),
S. 765.

Koopmans, T.C. (1947)
Measurement without Theory; Review of
Economic Statistics, XXIX, S. 161.

Krishnaiah, P.R. (Hrsg.) (1969)
Multivariate Analysis - II; New York.

Leuthold, R.M. et al. (1970)
Forecasting Daily Hog Prices and Quantities -
A Study of Alternative Forecasting Techniques;
Journal of the American Statistical Association,
65, S. 90.

Malinvaud, E. (1970)
Statistical Methods of Econometrics;
Amsterdam.

Mandell, L., Katona, G., Morgan, J.N.,
Schmiedeskamp, J. (Hrsg.) (1973)
Surveys of Consumers 1971-1972; Ann Arbor.

Marquardt, D.W. (1963)
An Algorithm for Least-Squares Estimation of
Nonlinear Parameters; Journal of the Society
for Industrial and Applied Mathematics, 2, S. 431.

Maynes, E.S. (1967)
 An Appraisal of Consumer Anticipation
 Approaches to Forecasting; Proceedings of
 the Business and Economic Statistics Section
 the American Statistical Association, S. 114.

Mincer, J. (Hrsg.) (1969)
 Economic Forecasts and Expectations; New York.

Mincer, J., Zarnowitz, V. (1969)
 The Evaluation of Economic Forecasts; in:
 Mincer (1969), S. 3.

Montgomery, D.C., Johnson, L.A. (1976)
 Forecasting and Time Series Analysis;
 New York.

Mueller, E. (1963)
 Ten Years of Consumer Attitudes Surveys:
 Their Forecasting Record; Journal of the
 American Statistical Association, 58, S. 899.

Naylor, T.H., Seaks, T.G., Wichern, D.W. (1972)
 Box-Jenkins Methods: An Alternative to Econometric
 Models; International Statistical Review, 40,
 S. 123.

Nelson, C.R. (1972)
 The Prediction Performance of the F.R.B.-M.I.T.-
 PENN Model of the U.S. Economy; American Economic
 Review, 62, S. 902.

Nelson, C.R. (1973)
 Applied Time Series Analysis for Managerial
 Forecasting; San Francisco.

Nerlove, M., Wallis, K.F. (1966)
 Use of the Durbin-Watson Statistic in
 Inappropriate Situations; Econometrica, 34,
 S. 235.

Newbold, P., Granger, C.W.J. (1974)
Experience with Forecasting Univariate
Time Series and the Combination of
Forecasts; Journal of Royal Statistical
Society, A, 137, S. 131.

Orcutt, G.H. (1948)
A Study of the Autoregressive Nature of the
Time Series Used for Tinbergen's Model of the
Economic System of the United States, 1919 -
1932; Journal of Royal Statistical Society,
B, 10, S. 1.

Parzen, E. (1969)
Multiple Time Series Modelling; in: Krishnaiah
(1969), S. 389.

Pierce, D.A. (1972)
Residual Correlations and Diagnostic Checking
in Dynamic-Disturbance Time Series Models;
Journal of the American Statistical Association,
67, S. 636.

Pierce, D.A. (1977)
Relationships - and the Lack Thereof -
Between Economic Time Series, with Special
Reference to Money and Interest Rates;
Journal of the American Statistical Association,
72, S. 11.

Pierce, D.A., Haugh, L.D. (1977)
Causality in Temporal Systems; Journal of
Econometrics, 5, S. 265.

Pindyck, R.S., Rubinfeld, D.L. (1976)
Econometric Models and Economic Forecasts;
New York.

Priestley, M.B. (1971)
Fitting Relationships Between Time Series;
Bulletin of the International Statistical
Institute, 44, S. 295.

Prothero, D.L., Wallis, K.F. (1976)
Modelling Macroeconomic Time Series;
Journal of Royal Statistical Society,
A, 139. S. 468.

Reid, D.J. (1969)
A Comparative Study of Time Series Prediction
Techniques on Economic Data; Nottingham.

Rowley, J.C.R. (1973)
Econometric Estimation; New York.

Sargan, J.D. (1961)
The Maximum Likelihood Estimation
of Economic Relationships with
Autoregressive Residuals; Econometrica, 29, S. 414.

Shapiro, H.T. (1972)
The Index of Consumer Sentiment and Economic
Forecasting: A Reappraisal; in: Strumpel/Morgan/
Zahn (1972), S. 373.

Sims, C.A. (1972)
Comment; Journal of the American Statistical
Association, 72, S. 23.

Spencer, M.H., Clark, C.G., Hoguet, P.W. (1965)
Business and Economic Forecasting; Homewood.

Staff of the Economic Behavior Program, Survey
Research Center (1962)
Fifteen Years of Experience with the Measurement
of Consumer Expectations; Proceedings of the
Business and Economic Statistics Section of the
American Statistical Association, S. 169.

Stekler, H.O. (1970)
Economic Forecasting; New York.

Stöwe, H. (1977)
Ökonometrie; Meisenheim am Glan.

Suits, D. (1962)
Forecasting and Analysis with an Econometric
Model; American Economic Review, 12, S. 104.

Suits, D., Sparks, G. (1965)
Consumption Regression with Quarterly Data;
in: Duesenberry et al. (1965), S. 203.

Survey Research Center (fortlaufend)
Surveys of Consumer Finances; Ann Arbor.

Survey Research Center (1976)
Fragebogen der Umfrage 1976.3.

Theil, H. (1971)
Principles of Econometrics; New York.

Theil, H., Boot, J.C.G. (1962)
The Final Form of Econometric Equation
Systems; Review of the International
Statistical Institute, 30, S. 136.

Tinbergen, J. (1939)
Statistical Testing of Business Cycle
Theories, Vol. II, Business Cycles in the
United States of America 1919 - 1932;
Genf 1939.

Tukey, J.W. (1961)
Discussion Emphasizing the Connection
Between Analysis of Variance and Spectrum
Analysis; Technometrics, 3, S. 191.

Whittle, P. (1951)
Hypothesis Testing in Time Series
Analysis; Uppsala.

Zellner, A., Palm, F. (1974)
Time Series Analysis and Simultaneous
Equation Econometric Models; Journal of
Econometrics, 2, S. 17.

o.V. (1964)
Models of Income Determination; Studies in
Income and Wealth; Vol. 28, Princeton.

Als Quellen der Beobachtungen der ökonomischen Serien wurden neben den Daten-Bändern des "Survey Research Center" verwendet:

United States Department of Commerce/Bureau of Economic Analysis:

Handbook of Cyclical Indicators - A Supplement to the Business Conditions Digest; Washington 1977.

The National Income and Product Accounts of the United States, 1929 - 1974; Washington 1977.

Business Conditions Digest (fortlaufend).

Survey of Current Business (fortlaufend).

Lebenslauf

Am 28.8.1946 wurde ich in Wiesbaden als Sohn des Dekorateurs Willi Doeblin und seiner Ehefrau Lina geboren.

Von 1953 bis 1957 besuchte ich die Diesterweg-Volksschule und ab 1957 das Oranien-Gymnasium in Wiesbaden, wo ich 1966 die Reifeprüfung ablegte.

An der Johannes Gutenberg-Universität Mainz studierte ich vom Wintersemester 1966 bis zum Sommersemester 1969 Publizistik. Vom Wintersemester 1969/70 bis zum Sommersemester 1974 studierte ich Volkswirtschaftslehre. Nach bestandener Diplomprüfung nahm ich beginnend am 1.9.1974 an einem 18-monatigen Ausbildungsprogramm des "Instituts für Demoskopie, Allensbach" teil.

Ab August 1976 war ich als "Visiting Scholar" im Zusammenhang mit der Erstellung meiner Dissertation für 19 Monate am "Institute for Social Research/Survey Research Center", University of Michigan, Ann Arbor, USA, sowie an anderen amerikanischen Universitäten. Die mündliche Doktorprüfung bestand ich am 7.2.1979.

Jürgen Doeblin

